



Universidad
Carlos III de Madrid

Departamento de Ingeniería Mecánica

PROYECTO FIN DE CARRERA

MONITORIZACIÓN Y CLASIFICACIÓN DE DEFECTOS EN RODAMIENTOS DE BOLAS. ESTUDIO TRANSITORIO

Autor: Miguel Albertos Cabañas

Tutor: Dra. Cristina Castejón Sisamón

Leganés, marzo de 2011

Título: Monitorización y clasificación de defectos en rodamientos de bolas. Estudio transitorio

Autor: Miguel Albertos Cabañas

Director: Dra. Cristina Castejón Sisamón

EL TRIBUNAL

Presidente: Higinio Rubio Alonso

Vocal: Antonia Jiménez Morales

Secretario: Álvaro García Hernández

Realizado el acto de defensa y lectura del Proyecto Fin de Carrera el día 16 de Marzo de 2011 en Leganés, en la Escuela Politécnica Superior de la Universidad Carlos III de Madrid, acuerda otorgarle la CALIFICACIÓN de

SECRETARIO

VOCAL

PRESIDENTE

Agradecimientos

Durante la realización del presente Proyecto Fin de Carrera he contado con la colaboración y el apoyo de numerosas personas a las que me gustaría destacar:

Agradecer la ayuda y tutela de la Dra. Cristina Castejón Sisamón y Alberto Ordoñez Rangel, así como al Dr. Juan Carlos García Prada por introducirme en este proyecto de investigación.

A mis amigos y a mis compañeros de la Universidad Carlos III, a mi familia y a mi novia por el apoyo prestado a lo largo de toda la carrera.

Muchas gracias a todos

Resumen

Hoy en día, los rodamientos son los elementos de apoyo de ejes más empleados junto con los cojinetes en máquinas rotativas, soportando gran parte de la carga y sometidos a numerosos esfuerzos, por lo que la posibilidad de aparición de un defecto incipiente en su estructura es elevada.

Esto ha generado en las últimas décadas un esfuerzo económico importante para desarrollar y mejorar los métodos automáticos de detección de defectos en los procesos industriales, ya que va acompañado de una cuantiosa reducción de los costes operacionales y de mantenimiento.

De todos los métodos existentes debemos hacer hincapié en métodos no invasivos como el análisis de vibraciones mecánicas, ya que nos permiten conocer el estado de la máquina interfiriendo mínimamente en el proceso productivo.

Y es en este punto en el que el presente Proyecto comienza su desarrollo, con el interés en desarrollar nuevos métodos de detección de defectos en rodamientos a partir de señales vibratorias. Para ello nos centramos en un tipo concreto de señal, la obtenida de un rodamiento sometido a una rampa de velocidad, y un objetivo, desarrollar un método que permita identificar el estado del rodamiento a partir de esta señal. Para ello se adquieren un conjunto de señales en un banco de ensayos habilitado para la obtención de señales en rodamientos. Estos rodamientos corresponden a cuatro condiciones de operación diferentes: una define el estado de rodamiento sano y las otras tres corresponden a tres condiciones de defecto. Las señales obtenidas serán procesadas con Transformadas Wavelet y Wavelet Packet para determinar los niveles que mejor definen cada tipo de señal y obtendremos distintos patrones con el fin de encontrar el que nos permita identificar el tipo de rodamiento. Para ello introduciremos estos patrones en diferentes tipos de red neuronal, para así desarrollar un sistema inteligente capaz de, a partir de señales obtenidas clasificar e identificar su procedencia, imitando con ello el procedimiento de aprendizaje humano.

De los resultados obtenidos se concluirá qué métodos de procesamiento son más eficaces, los tipos de redes más apropiados para este tipo de señales así como su configuración óptima para obtener buenos resultados.

Abstract

Nowadays, bearings are the elements of shaft supporting most used in rotating machinery, so the possibility of have a defect in its structure is quite a bit high.

This has led in last decades an economic effort to develop and improve methods for automatic detection of failures in industrial processes, and that's because it leads an important reduction in operational and maintenance costs.

We would like to emphasize in non-invasive methods such as mechanical vibration analysis, as they allow us to know the status of the machine with minimal disruption in the production process.

It's at this moment when this project began, with interest in developing new methods of detection of failures in bearings from vibration signals. To do this we focus on a particular type of signal obtained from a bearing subjected to transient effort. Obviously we need a goal too, develop a method to identify the state of bearing from their vibration signals. For this purpose we acquired a set of signals on a test simulator enabled to obtain signals from ball bearings. We have four types of bearings, one is a healthy bearing and the other three are three kinds of bearings with little failures. The signals obtained are processed with Wavelet Transform and Wavelet Packet to know the levels that are able to define each type of signal. Thanks to it we can get some different patterns that allow us to classify signals. Introducing these patterns in different models of neural networks we can achieve an intelligent system capable to classify and identify the source. It's like human learning process.

In this way we can conclude which methods are more effective processing different types of networks suitable for each kind of signals, as well as their optimal settings to get the best results.

Glosario

- ANSI.- “American National Standards Institute”. Instituto Nacional de Estándares Americano.
- ART.- “Adaptative Resonance Theory”. Teoría de la Resonancia Adaptativa.
- BCF.- “Bearing Characteristic Frequencies”. Frecuencias Características del Rodamiento.
- BPFI.- “Ball Pass Frequency Inner race”. Frecuencia de Paso de la Bola por la pista Interna.
- BPFO.- “Ball Pass Frequency Outer race”. Frecuencia de Paso de la Bola por la pista Externa.
- BSF.- “Ball Spin Frequency”. Es la Frecuencia de paso de algún defecto de de la bola.
- CFF.- “Cage Fault Frequency” Frecuencia de defecto de la jaula del rodamiento.
- CFS.- Coeficientes del paquete Wavelet
- CWD.- “Choi-Williams Distribution”. Distribución Choi-Williams.
- CWT.- “Continue Wavelet Transform”. Transformada Continua Wavelet.
- DWT.- “Discrete Wavelet Transform”. Transformada Discreta Wavelet.
- FF.- “Feed Forward”. Referido a red neuronal perceptrón multicapa Feedforward.
- FFT.- “Fast Fourier Transform”. Transformada Rápida de Fourier.
- FT.- “Fourier Transform”. Transformada de Fourier.
- ISO.- “International Standards Organization”. Organización Internacional de Estándares.
- MLP.- “Multi Layer Perceptron”. Perceptron Multicapa.
- MRA.- “Multi Resolution Analysis”. Análisis Multiresolución.
- MSE.- “Mean Square Error”. Error Cuadrático Medio.
- MSNE.- “Mean Square Normalized Error”. Error Cuadrático Medio Normalizado.
- PCA.- “Principal Component Analysis”. Análisis de Componentes Principales.
- PFC.- Proyecto Fin de Carrera.
- PNN.- “Probabilistic Neural Network”. Red Neuronal Probabilística.
- PR.- “Pattern Recognition”. Reconocimiento de Patrones.
- RBF.- “Radial Basis Function”. Función de base Radial.
- RCFS.- Reconstrucción de los coeficientes del paquete Wavelet
- RNA.- “Red Neuronal Artificial”.
- RPM.- “Revolutions Per Minute”. Revoluciones por minuto.
- SOM.- “Self Organizing Maps”. Mapas Auto Organizados.
- STFT.- “Short Time Fourier Transform”. Transformada Corta de Fourier.
- WP.- “Wavelet Packets”. Paquetes Wavelet.
- WT.- “Wavelet Transform”. Transformada de funciones Wavelet.

Índice

AGRADECIMIENTOS	4
RESUMEN.....	5
ABSTRACT	6
GLOSARIO	7
ÍNDICE	8
ÍNDICE DE ILUSTRACIONES.....	11
ÍNDICE DE TABLAS.....	14
CAPÍTULO 1: INTRODUCCIÓN.....	15
1.1 ANTECEDENTES.....	17
1.2 OBJETIVOS.....	18
1.3 JUSTIFICACIÓN DEL PROYECTO	18
1.4 FASES DE DESARROLLO	18
1.5 MEDIOS EMPLEADOS.....	19
1.6 ORGANIZACIÓN DEL PROYECTO FIN DE CARRERA.....	19
CAPÍTULO 2: ESTADO DEL ARTE	20
2.1 EL MANTENIMIENTO PREDICTIVO.....	21
2.1.1 <i>Introducción</i>	21
2.1.2 <i>Situación actual</i>	21
2.1.3 <i>Aplicación y metodología</i>	22
2.1.4 <i>Técnicas aplicadas al mantenimiento predictivo</i>	22
2.1.5 <i>Mantenimiento Pro-activo</i>	27
2.1.6 <i>Conclusión</i>	27
2.2 PROCESAMIENTO DE SEÑALES VIBRATORIAS	28
2.2.1 <i>Introducción</i>	28
2.2.2 <i>Clasificación de las señales vibratorias</i>	29
2.2.3 <i>Modelo de procesamiento de señales vibratorias.</i>	29
2.2.4 <i>Tipos de análisis de señales vibratorias</i>	30
Nivel básico de diagnóstico de fallos	30
Nivel medio. Análisis temporales-estadísticos.....	31
Nivel avanzado de diagnóstico de fallas.....	32
2.3 LA TRANSFORMADA DE FOURIER O FT (FOURIER TRANSFORM)	33
2.4 LA TRANSFORMADA WAVELET	35
2.4.1 <i>Introducción</i>	35
2.4.2 <i>Transformada Wavelet Continua (CWT)</i>	36
2.4.3 <i>La Transformada Wavelet Discreta (DWT)</i>	37
2.4.4 <i>Energía de señales de vibración</i>	39
2.4.5 <i>Aplicaciones</i>	40
2.5 REDES NEURONALES ARTIFICIALES (RNA's).....	41
2.5.1 <i>Introducción</i>	41
2.5.2 <i>Elementos básicos que componen una red neuronal</i>	41
2.5.3 <i>Niveles o capas de una red neuronal</i>	44
2.5.4 <i>Clasificación de las redes neuronales artificiales</i>	45

2.5.5 Mecanismos de aprendizaje	45
2.5.6 Topología de las redes neuronales.....	47
Redes de Hopfield.....	47
Redes competitivas.....	48
Redes Perceptrón Multicapa.....	49
Redes de Base Radial	49
Mapas Autoorganizados o Redes SOM (Self Organized Map).....	50
CAPÍTULO 3: SISTEMA EXPERIMENTAL	51
3.1 INTRODUCCIÓN	52
3.2 SISTEMA EXPERIMENTAL	52
3.2.1 Los rodamientos.....	52
Tipos de rodamientos.....	53
Principales causas de fallos y defectos	55
Rodamientos empleados.....	57
3.2 EL SISTEMA DE ENSAYOS.....	60
3.3 METODOLOGÍA DEL ENSAYO.....	64
Descripción del ensayo.....	64
Configuración del sistema de ensayos.....	65
Tamaño y duración de la muestra	65
CAPÍTULO 4: SISTEMA DE DETECCIÓN Y DIAGNOSIS.....	66
4.1 PROCESAMIENTO DE LAS SEÑALES OBTENIDAS	67
4.1.1 El entorno MATLAB.....	67
4.1.2 Señales obtenidas del ensayo	68
4.1.3 Métodos de procesamiento de la señal empleados.....	68
4.2 SISTEMA CLASIFICADOR	75
4.2.1 MATLAB	75
4.2.2 FUNCIONES Y PARÁMETROS DE MATLAB.....	75
4.2.3 TOPOLOGÍAS DE RED	77
Red de base radial	77
Red perceptrón multicapa feedforward	78
Red perceptrón multicapa de reconocimiento de patrones	78
Red SOM	79
4.2.4 ENTRENAMIENTO, SIMULACIÓN Y TEST.....	79
CAPÍTULO 5: RESULTADOS	83
5.1 SEÑAL ÍNTEGRA.....	84
Red de base radial.....	85
Red perceptrón multicapa feedforward.....	85
Red perceptrón multicapa de reconocimiento de patrones	85
Red SOM	85
5.2 PAQUETE WAVELET RECONSTRUIDO (RCFS).....	86
5.3 COEFICIENTES DEL PAQUETE WAVELET (CFS).....	93
NIVEL 5	93
Análisis CFS 5.1: CFS nivel 5 paquete 29. RBF.....	94
Análisis CFS 5.2: CFS nivel 5 paquete 18. RBF.....	96
Análisis CFS 5.3: CFS nivel 5 paquete 18. Feedforward. 240 neuronas.....	96
Análisis CFS 5.4: CFS nivel 5 paquete 29. Feedforward. 240 neuronas.....	98
Análisis CFS 5.5: CFS nivel 5 paquete 29. Feedforward. Dos capas ocultas 240x24.	98
Análisis CFS 5.6: CFS nivel 5 paquete 18. Rec. Patrones. 240 neuronas.	98
Análisis CFS 5.7: CFS nivel 5 paquete 29. Rec. Patrones. 240 neuronas.	100

Análisis CFS 5.8: CFS nivel 5 paquete 18. SOM. Red de 10x10 neuronas.....	100
NIVEL 8	101
Análisis CFS 8.1: CFS Nivel 8 paquete 174. RBF	102
Análisis CFS 8.2: CFS Nivel 8 paquete 145.RBF	104
Análisis CFS 8.3: CFS Nivel 8 paquete 174. Feedforward. 240 neuronas.	104
Análisis CFS 8.4: CFS Nivel 8 paquete 174. Feedforward. Dos capas ocultas 240x24	105
Análisis CFS 8.5: CFS Nivel 8 paquete 174. Rec.patrones. 240 neuronas.....	107
Análisis CFS 8.6: CFS Nivel 8 paquete 174. SOM. Red 10x10 neuronas	107
NIVEL 10	108
Análisis CFS 10.1: CFS nivel 10 paquete 698 RBF	108
Análisis CFS 10.2: CFS nivel 10 paquete 698. Feedforward. Dos capas ocultas 240x24	109
Análisis CFS 10.3: CFS Nivel 10 paquete 698. Rec.patrones. 240 neuronas.....	109
Análisis CFS 10.4: CFS Nivel 10 paquete 698. Red 10x10 neuronas	110
CONCLUSIÓN.....	110
5.4 ENERGÍA	111
NIVEL 5	111
Análisis Energía 5.1: Energía nivel 5. RBF	111
Análisis Energía 5.2: Energía nivel 5. Feedforward. 20 Neuronas	114
Análisis Energía 5.3: Energía nivel 5. Rec. Patrones. 20 neuronas	116
Análisis 5.4. Energía nivel 5: SOM. 10x10 neuronas.	117
NIVEL 8	119
Análisis Energía 8.1: Energía nivel 8. RBF	120
Análisis Energía 8.2: Energía nivel 8. Feedforward. 20 Neuronas	122
Análisis Energía 8.3: Energía nivel 8. Rec. Patrones. 20 Neuronas	124
Análisis Energía 8.4: Energía nivel 8. SOM. 10x10 neuronas.	125
CONCLUSIÓN.....	127
5.5 RESUMEN	127
CAPÍTULO 6: CONCLUSIONES	130
6.1 CONCLUSIONES SOBRE LOS RESULTADOS OBTENIDOS.....	131
6.2 COMPARACIÓN CON OTROS TRABAJOS	131
6.3 PUNTOS DE MEJORA.....	132
6.4 FUTUROS DESARROLLOS	133
6.5 CONOCIMIENTOS EMPLEADOS Y ADQUIRIDOS	133
PRESUPUESTO.....	134
BIBLIOGRAFÍA	135

Índice de ilustraciones

ILUSTRACIÓN 1: MOTOR AVERIADO DE UN AIRBUS A-380	16
ILUSTRACIÓN 2: DIFERENTES TÉCNICAS UTILIZADAS EN EL MANTENIMIENTO PREDICTIVO [2].....	22
ILUSTRACIÓN 3: REGISTRO DE VIBRACIONES EN UN CICLO DE TRABAJO EN FUNCIÓN DEL TIEMPO.....	23
ILUSTRACIÓN 4: TRANSFORMADA TIEMPO-FRECUENCIA	23
ILUSTRACIÓN 5: ANÁLISIS DE ACEITES. PRESENCIA DE PARTÍCULAS SÓLIDAS	24
ILUSTRACIÓN 6: ANÁLISIS POR ULTRASONIDOS	25
ILUSTRACIÓN 7: ANÁLISIS TERMOGRÁFICO DE UN INTERRUPTOR	26
ILUSTRACIÓN 8: ESTUDIO DE ANÁLISIS ELÉCTRICO	27
ILUSTRACIÓN 9: CLASIFICACIÓN DE LAS SEÑALES VIBRATORIAS [6].....	29
ILUSTRACIÓN 10: ESQUEMA METODOLÓGICO DE LA TRANSFORMACIÓN DE LA INFORMACIÓN [6]	30
ILUSTRACIÓN 11: ZOOM Y ANÁLISIS DE ENVOLVENTE [9]	31
ILUSTRACIÓN 12: ORBITAS ROTOR DESBALANCEADO CON Y SIN PRECARGAS [9].....	32
ILUSTRACIÓN 13: REPRESENTACIÓN DE FFT DE UNA SEÑAL [3]	34
ILUSTRACIÓN 14: REPRESENTACIÓN DE STFT DE UNA SEÑAL MUSICAL [3]	35
ILUSTRACIÓN 15: WAVELETS MADRE MÁS EMPLEADAS.....	36
ILUSTRACIÓN 16: SEÑAL SINUSOIDAL Y SU TRANSFORMADA WAVELET [7]	37
ILUSTRACIÓN 17: COMPARACIÓN DE LA VENTANA DE TRANSFORMACIÓN DE UNA STFT Y UNA WT [14].....	38
ILUSTRACIÓN 18: ÁRBOL DE DESCOMPOSICIÓN WAVELET.....	39
ILUSTRACIÓN 19: (A) SEÑAL TEMPORAL $x(t)$, (B) ENERGÍA DE LA SEÑAL $x(t)$,	39
ILUSTRACIÓN 20: COMPARACIÓN ENTRE NEURONA BIOLÓGICA Y NEURONA ARTIFICIAL [3]	41
ILUSTRACIÓN 22: ESTRUCTURA BÁSICA DE UNA NEURONA.....	41
ILUSTRACIÓN 23: ESQUEMA BÁSICO DE UNA RED NEURONAL	44
ILUSTRACIÓN 21: CLASIFICACIÓN DE LAS REDES NEURONALES	45
ILUSTRACIÓN 24: TOPOLOGÍA DE UNA RED DE HOPFIELD	48
ILUSTRACIÓN 25: TOPOLOGÍA DE UNA RED COMPETITIVA.....	48
ILUSTRACIÓN 26: TOPOLOGÍA DE UNA RED PERCEPTRÓN MULTICAPA.....	49
ILUSTRACIÓN 27: TOPOLOGÍA DE UNA RED DE BASE RADIAL [19]	50
ILUSTRACIÓN 28: TOPOLOGÍA DE UNA RED SOM.....	50
ILUSTRACIÓN 29: ESQUEMA DEL PROCESO DE CLASIFICACIÓN DE LAS SEÑALES.....	52
ILUSTRACIÓN 30: PARTES QUE COMPONEN UN RODAMIENTO	53
ILUSTRACIÓN 31: ESQUEMA DE CLASIFICACIÓN DE RODAMIENTOS	53
ILUSTRACIÓN 32: TIPOS DE RODAMIENTOS RADIALES	54
ILUSTRACIÓN 33: TIPOS DE RODAMIENTOS AXIALES	54
ILUSTRACIÓN 34: TIPOS DE RODAMIENTOS MIXTOS	55
ILUSTRACIÓN 35: TIPOS DE DEFECTOS EN RODAMIENTOS	56
ILUSTRACIÓN 36: CAUSA DE DEFECTOS EN RODAMIENTOS [25].....	56
ILUSTRACIÓN 37: PRINCIPALES CAUSAS DE DEFECTOS EN RODAMIENTOS.....	57
ILUSTRACIÓN 38: ER10K DE MB MANUFACTURING.....	57
ILUSTRACIÓN 39: SECCIÓN FRONTAL Y TRANSVERSAL DE UN RODAMIENTO	59
ILUSTRACIÓN 40: MACHINE FAULT SIMULATOR LITE	60
ILUSTRACIÓN 41: ELEMENTOS QUE COMPONEN LA MACHINE FAULT SIMULATOR LITE.....	61
ILUSTRACIÓN 42: ACCELERÓMETRO TRIAXIAL MMF KS 943B.10 Y MEDIDAS.....	61
ILUSTRACIÓN 43: RESPUESTA EN FRECUENCIA DEL ACCELERÓMETRO TRIAXIAL MMF KS 943B.10	62
ILUSTRACIÓN 44: FILTRO UTILIZADO	63
ILUSTRACIÓN 45: TARJETA DE ADQUISICIÓN DE DATOS	63
ILUSTRACIÓN 46: CADENA DE MEDIDA	64

ILUSTRACIÓN 47: MATLAB	67
ILUSTRACIÓN 48: <i>WAVEMENU</i>	67
ILUSTRACIÓN 49: SEÑAL OBTENIDA DE TESTPOINT	68
ILUSTRACIÓN 50: ESQUEMA DE TRATAMIENTO PREVIO DE LA SEÑAL	69
ILUSTRACIÓN 51: ESQUEMA DE PROCESAMIENTO	69
ILUSTRACIÓN 52: WAVELET PACKET	70
ILUSTRACIÓN 53: TRANSFORMADA WAVELET CONTINUA	71
ILUSTRACIÓN 54: SEÑAL ÍNTEGRA	71
ILUSTRACIÓN 55: ENERGÍA DE CADA PAQUETE DEL OCTAVO NIVEL DE TODAS LAS SEÑALES (DB6)	73
ILUSTRACIÓN 56: TIPOS DE ANÁLISIS REALIZADOS DEPENDIENDO DEL PROCESAMIENTO DE SEÑALES EMPLEADO	74
ILUSTRACIÓN 57: <i>NEURAL NETWORK TRAINING DISPLAY</i>	75
ILUSTRACIÓN 58: EJEMPLO ENTRENAMIENTO DE RED	80
ILUSTRACIÓN 59: MATRIZ DE CONFUSIÓN DE LA SIMULACIÓN	81
ILUSTRACIÓN 60: MATRIZ DE CONFUSIÓN DEL TEST 3	82
ILUSTRACIÓN 61: EJEMPLO DE AGRUPACIÓN DE LOS RESULTADOS DE CLASIFICACIÓN: 1: RODAMIENTO SANO. 2: DEFECTO EN PISTA INTERNA. 3: DEFECTO EN PISTA EXTERNA. 4: DEFECTO EN BOLA	82
ILUSTRACIÓN 62: SEÑALES TÍPICAS DE LOS RODAMIENTOS ANALIZADOS	84
ILUSTRACIÓN 63: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS SANOS DEL PAQUETE WAVELET 29 DEL NIVEL 5 DE UNA TRANSFORMADA DAUBECHIES DB6	86
ILUSTRACIÓN 64: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS SANOS DEL PAQUETE WAVELET 29 DEL NIVEL 5 DE UNA TRANSFORMADA DAUBECHIES DB6	87
ILUSTRACIÓN 65: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS CON DEFECTO EN PISTA EXTERNA DEL PAQUETE WAVELET 29 DEL NIVEL 5 DE UNA TRANSFORMADA DAUBECHIES DB6	87
ILUSTRACIÓN 66: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS CON DEFECTO EN BOLA DEL PAQUETE WAVELET 29 DEL NIVEL 5 DE UNA TRANSFORMADA DAUBECHIES DB6	88
ILUSTRACIÓN 67: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS SANOS DEL PAQUETE WAVELET 145 DEL NIVEL 8 DE UNA TRANSFORMADA DAUBECHIES DB6	88
ILUSTRACIÓN 68: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS CON DEFECTO EN PISTA INTERNA DEL PAQUETE WAVELET 145 DEL NIVEL 8 DE UNA TRANSFORMADA DAUBECHIES DB6	89
ILUSTRACIÓN 69: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS CON DEFECTO EN PISTA EXTERNA DEL PAQUETE WAVELET 145 DEL NIVEL 8 DE UNA TRANSFORMADA DAUBECHIES DB6	89
ILUSTRACIÓN 70: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS CON DEFECTO EN BOLA DEL PAQUETE WAVELET 145 DEL NIVEL 8 DE UNA TRANSFORMADA DAUBECHIES DB6	90
ILUSTRACIÓN 71: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS SANOS DEL PAQUETE WAVELET 554 DEL NIVEL 10 DE UNA TRANSFORMADA DAUBECHIES DB6	90
ILUSTRACIÓN 72: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS CON DEFECTO EN PISTA INTERNA DEL PAQUETE WAVELET 554 DEL NIVEL 10 DE UNA TRANSFORMADA DAUBECHIES DB6	91
ILUSTRACIÓN 73: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS CON DEFECTO EN PISTA EXTERNA DEL PAQUETE WAVELET 554 DEL NIVEL 10 DE UNA TRANSFORMADA DAUBECHIES DB6	91
ILUSTRACIÓN 74: MUESTRA DE 20 SEÑALES RECONSTRUIDAS DE RODAMIENTOS CON DEFECTO EN BOLA DEL PAQUETE WAVELET 554 DEL NIVEL 10 DE UNA TRANSFORMADA DAUBECHIES DB6	92
ILUSTRACIÓN 75: GRÁFICA DE ENERGÍAS. NIVEL DE DESCOMPOSICIÓN 5	94
ILUSTRACIÓN 76: ENTRENAMIENTO DEL ANÁLISIS CFS 5.1	94
ILUSTRACIÓN 77: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS CFS 5.1	95
ILUSTRACIÓN 78: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS CFS 5.1	96
ILUSTRACIÓN 79: ANÁLISIS CFS 5.3: CFS NIVEL 5 PAQUETE 18	96
ILUSTRACIÓN 80: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS CFS 5.3	97
ILUSTRACIÓN 81: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS CFS 5.3	98
ILUSTRACIÓN 82: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS CFS 5.6	98
ILUSTRACIÓN 83: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS CFS 5.6	99

ILUSTRACIÓN 84: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS CFS 5.6	100
ILUSTRACIÓN 85: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS CFS 5.8.....	100
ILUSTRACIÓN 86: GRÁFICA DE ENERGÍAS. NIVEL DE DESCOMPOSICIÓN 8	101
ILUSTRACIÓN 87: RESULTADOS DEL ENTRENAMIENTO. ANÁLISIS CFS 8.1	102
ILUSTRACIÓN 88: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS CFS 8.1	102
ILUSTRACIÓN 89: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS CFS 8.1	103
ILUSTRACIÓN 90: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS CFS 8.3.....	104
ILUSTRACIÓN 91: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS CFS 8.3	104
ILUSTRACIÓN 92: CONFIGURACIÓN DE LA RED NEURONAL DEL ANÁLISIS CFS 8.4	105
ILUSTRACIÓN 93: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS CFS 8.4.....	105
ILUSTRACIÓN 94: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS CFS 8.4	106
ILUSTRACIÓN 95: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS CFS 8.4	107
ILUSTRACIÓN 96: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS CFS 8.6.....	107
ILUSTRACIÓN 97: GRÁFICA DE ENERGÍAS. NIVEL 10.....	108
ILUSTRACIÓN 98: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS CFS 10.2	109
ILUSTRACIÓN 99: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS CFS 10.4.....	110
ILUSTRACIÓN 100: GRÁFICO DE ENERGÍAS. NIVEL 5 CON LOS PAQUETES UTILIZADOS	111
ILUSTRACIÓN 101: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 5.1.....	112
ILUSTRACIÓN 102: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 5.1	112
ILUSTRACIÓN 103: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS ENERGÍA 5.1	113
ILUSTRACIÓN 104: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 5.2.....	114
ILUSTRACIÓN 105: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 5.2	114
ILUSTRACIÓN 106: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS ENERGÍA 5.2	115
ILUSTRACIÓN 107: ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 5.3	116
ILUSTRACIÓN 108: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 5.3	116
ILUSTRACIÓN 109: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS ENERGÍA 5.3	117
ILUSTRACIÓN 110: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS 5.4	118
ILUSTRACIÓN 111: RESULTADOS DE LA SIMULACIÓN DEL ANÁLISIS 5.4	118
ILUSTRACIÓN 112: GRÁFICA DE ENERGÍAS CENTRADA EN EL RANGO DE VALORES EMPLEADOS	119
ILUSTRACIÓN 113: RESULTADO DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 8.1	120
ILUSTRACIÓN 114: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 8.1	120
ILUSTRACIÓN 115: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS ENERGÍA 8.1	121
ILUSTRACIÓN 116: RESULTADO DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 8.2	122
ILUSTRACIÓN 117: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 8.2	122
ILUSTRACIÓN 118: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS ENERGÍA 8.2	123
ILUSTRACIÓN 119: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 8.3.....	124
ILUSTRACIÓN 120: MATRIZ DE CONFUSIÓN DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 8.3	124
ILUSTRACIÓN 121: MATRICES DE CONFUSIÓN DE LA SIMULACIÓN DEL ANÁLISIS ENERGÍA 8.3	125
ILUSTRACIÓN 122: RESULTADOS DEL ENTRENAMIENTO DEL ANÁLISIS ENERGÍA 8.4.....	126
ILUSTRACIÓN 123: RESULTADOS DE LA SIMULACIÓN DEL ANÁLISIS ENERGÍA 8.4	126

Índice de tablas

TABLA 1: PRINCIPALES CARACTERÍSTICAS DEL ER10K.....	58
TABLA 2: CARACTERÍSTICAS DEL ACELERÓMETRO TRIAXIAL MMF KS 943B.10	62
TABLA 3: EJEMPLO DE TABLA DE MEJORES PAQUETES DE NIVEL 8 (DB6).....	73
TABLA 4: RED DE BASE RADIAL.....	78
TABLA 5: RED PERCEPTRÓN MULTICAPA FEEDFORWARD	78
TABLA 6: RED PERCEPTRÓN MULTICAPA DE RECONOCIMIENTO DE PATRONES.....	79
TABLA 7: RED SOM	79
TABLA 8: EJEMPLO TABLA DE TARGETS	80
TABLA 9: MEJORES PAQUETES WAVELET	93
TABLA 10: MEJORES PAQUETES WAVELET PARA NIVEL DE DESCOMPOSICIÓN 8.....	101
TABLA 11: MEJORES PAQUETES WAVELET. NIVEL 10.....	108
TABLA 12: PATRÓN DE ENERGÍA EMPLEADO. NIVEL 5	111
TABLA 13: PATRÓN DE ENERGÍA. NIVEL 8	119
TABLA 14: RESUMEN DE TODOS LOS ANÁLISIS REALIZADOS.....	129
TABLA 15: RESULTADOS DE CLASIFICACIÓN PARA UN NIVEL DE DESCOMPOSICIÓN 5 [7]	132
TABLA 16: RESULTADOS DE CLASIFICACIÓN PARA UN NIVEL DE DESCOMPOSICIÓN 8 [7]	132

CAPÍTULO 1: Introducción

Las máquinas rotativas juegan un papel crucial en aplicaciones industriales que afectan a sectores industriales como el aeronáutico, el naval, el energético, etc. La necesidad de incrementar la productividad de dichas máquinas y la fiabilidad de las mismas ha atraído el interés de la comunidad científica en lo referente al diseño de sistemas de diagnosis que permitan efectuar predicciones en tiempo real sobre su estado de “salud”.

Se puede afirmar que la capacidad de realizar pronósticos ajustados sobre el estado de funcionamiento de dichas máquinas supone un aspecto clave en su mantenimiento. Así, hay que indicar que el propósito de cualquier sistema de diagnosis es el análisis de información externa relevante de la maquinaria, generalmente a través de medidas indirectas como vibraciones, emisiones acústicas, control de partículas, etc., para establecer un plan de mantenimiento que o bien disminuya el coste de la reparación asociado a un modo de fallo, o bien alargue la vida efectiva de los componentes afectados por el fallo. De esta forma, se minimizarían los perjuicios provocados por una parada o por el funcionamiento anormal de la máquina.

La consecución del fin último que es la estimación de la vida útil de los componentes degradados implica no sólo la identificación y localización de daño sino también su cuantificación.

En el caso concreto de este Proyecto se centrará en uno de los elementos más importantes de cualquier máquina rotativa, el rodamiento de bolas, ya que sobre ellos se sustentan, y un fallo podría tener consecuencias catastróficas. Para ilustrar este comentario quiero destacar una noticia acontecida durante la realización del presente documento:

El 04 de noviembre de 2010, a las 3:45 a.m. (GMT) un A380 de la línea aérea australiana Qantas realizó un aterrizaje de emergencia en el aeropuerto de Singapur tras sufrir una fallo del motor 2 en el ala izquierda mientras sobrevolaba Indonesia (vuelo QF32 Londres - Sídney con escala en Singapur) [27]. En la Ilustración 1 se muestra el estado final del motor averiado.



Ilustración 1: Motor averiado de un Airbus A-380

Poco tiempo después salieron a la luz nuevos datos sobre el incidente:

El fabricante de motores Rolls Royce determinó que el accidente en el Airbus-380 se debió a un fallo en el rodamiento que desencadenó una fuga de aceite.

La empresa había realizado ajustes en los rodamientos de los motores Trent900, pero no a los más antiguos, diseñados en exclusiva para el superjumbo A380, según apuntó el director en jefe de operaciones de Airbus, John Leahy, en declaraciones que difundió el diario The Herald Sun.

La pieza en cuestión aloja los rodamientos de bolas que permiten dar vueltas a una barra que hace girar las turbinas dentro de los motores jet. Los investigadores dijeron que fue una fuga de aceite lo que causó un incendio en el motor del A380 de Qantas.

Este fallo de un rodamiento pudo haber costado vidas humanas de haberse dado peores circunstancias. Lo que sí que ha sucedido es que a raíz del fallo, Qantas suspendió todos los vuelos de sus A-380, y la imagen de Airbus y Rolls Royce ha quedado gravemente deteriorada, sucesos que supondrán graves pérdidas económicas a corto, medio y largo plazo.

Por hechos como los acontecidos las empresas actuales no tienen opción a la hora de apostar por un sistema de mantenimiento que permita evitar en la medida de lo posible fallos en sus equipos cuyas consecuencias pueden ser catastróficas.

1.1 Antecedentes

Desde mediados de la década de los noventa se han sucedido los estudios sobre clasificadores basados en redes neuronales. Se ha aplicado en numerosos campos y en la mayoría de estos va acompañado de un procesamiento de la señal previo a la clasificación para mejorar su exactitud.

Cabe destacar su uso en los siguientes campos:

- **Ámbito empresarial:**
 - Reconocimiento de caracteres escritos.
 - Identificación de candidatos para posiciones específicas.
 - Optimización de plazas y horarios en líneas de vuelo.
- **Medicina**
 - Analizadores del habla para sistemas de audición de sordos profundos.
 - Diagnóstico y tratamiento a partir de síntomas y/o de datos analíticos (encefalograma, etc.).
 - Monitorización en cirugía.
 - Predicción de reacciones adversas a los medicamentos.
- **Militares**
 - Clasificación de las señales de radar.
 - Creación de armas inteligentes.
 - Optimización del uso de recursos escasos
- **Medio Ambiente**
 - Previsión del tiempo.
 - Detección de seísmos.
 - Patrones de migración

- **Manufacturación**
 - Control de la calidad
 - Control de producción
 - Robots con visión artificial
 - Mejoras en el mantenimiento predictivo (detección temprana de defectos)
- **Finanzas**
 - Previsión de la evolución de los precios.
 - Valoración del riesgo de los créditos.
 - Identificación de falsificaciones.

1.2 Objetivos

Como hemos visto en el apartado anterior este Proyecto Fin de Carrera se enmarca dentro del mantenimiento industrial, y realizándolo se pretenden alcanzar los siguientes objetivos:

- **Objetivo principal:**

Desarrollar un método que nos permita detectar y clasificar el estado de un rodamiento de bolas sometido a esfuerzos transitorios.
- **Objetivos secundarios:**
 - Realización de ensayos experimentales de preparación y montaje del banco de ensayos, así como familiarización con el proceso de adquisición de datos.
 - Probar los distintos tipos de procesamiento wavelet y redes neuronales para determinar su efectividad trabajando con señales transitorias.
 - Abrir nuevos caminos para futuros desarrollos.

1.3 Justificación del Proyecto

La necesidad de nuevos métodos de mantenimiento preventivo así como la ausencia de procedimientos para detectar fallos en elementos sometidos a esfuerzos transitorios justifican el desarrollo de este PFC.

1.4 Fases de desarrollo

Para la realización del PFC se recorrerán diferentes fases:

1. Fase de aprendizaje: Durante esta fase se recopilarán y estudiarán las referencias bibliográficas y las fuentes de información disponibles.
2. Fase de iniciación: Se decidirán los métodos que se emplearán en su realización. Por ejemplo se decide usar el software Matlab, o empleamos el Rotor-kit de Spectra Quest...
3. Fase experimental: Se obtienen las señales experimentales del banco de ensayos.
4. Fase de desarrollo: Se crea un programa que sea capaz de procesar y clasificar esas señales.
5. Fase de redacción: Se genera el informe que da lugar al PFC.

1.5 Medios empleados

Para la ejecución del PFC se han empleado principalmente medios de la Universidad Carlos III de Madrid, como un banco de ensayos de rodamientos o equipos informáticos y literatura. También se han empleado medios propios como equipos informáticos de sobremesa y portátiles. Por último destacar un medio en el que se puede encontrar información útil de cualquier rama como es Internet.

1.6 Organización del Proyecto Fin de Carrera

El Proyecto Fin de Carrera está dividido en seis capítulos, ya que trataremos dentro del tema principal del Proyecto diferentes contenidos.

En el primer capítulo se abordará una breve introducción al PFC y se definirán las bases que lo componen.

En el segundo capítulo se introducirán y explicarán los fundamentos teóricos en los que se basa el Proyecto.

En el tercer capítulo se definirá el sistema experimental y los elementos que lo componen.

En el cuarto capítulo se explicará el sistema de detección y diagnóstico propuesto en todos sus ámbitos.

En el quinto capítulo se mostrarán los resultados obtenidos, presentando en un modo más extenso una serie de casos concretos y a modo de resumen el resto de resultados.

En el sexto capítulo se obtendrán las conclusiones de los resultados obtenidos y de la realización del PFC en sí y se propondrán futuros desarrollos en los campos abarcados.

Con esta organización se trata de enmarcar el PFC dentro de la nueva rúbrica propuesta por la Universidad Carlos III, y de este modo, facilitar su corrección y servir de modelo estructural a seguir para futuros desarrollos.

CAPÍTULO 2: Estado del arte

2.1 El Mantenimiento Predictivo

2.1.1 Introducción

La realidad industrial está caracterizada por la enorme necesidad de explotar eficaz y eficientemente la maquinaria instalada y elevar a niveles superiores la actividad del mantenimiento. No remediamos nada con grandes soluciones que presuponen diseños, innovaciones, y tecnologías de recuperación, si no mantenemos con una alta disponibilidad nuestra industria.

En las últimas décadas, las estrictas normas de calidad y la presión competitiva han obligado a las empresas a transformar sus departamentos de mantenimiento.

Por eso en la situación actual es imprescindible, tanto en las grandes como en las medianas empresas, la implantación de una estrategia de mantenimiento para aumentar la vida de sus componentes, mejorando así la disponibilidad de sus equipos y su confiabilidad, lo que repercute en la productividad de la planta.

La gestión del mantenimiento ha evolucionado mucho a lo largo del tiempo. El mantenimiento industrial, día a día, está rompiendo con las barreras del pasado. Actualmente, muchas empresas aplican la frase: “el mantenimiento es inversión, no gasto”.

El primer mantenimiento llevado a cabo por las empresas fue el llamado mantenimiento correctivo, también llamado mantenimiento de emergencia. Esta clase de mantenimiento consiste en solucionar los problemas de los equipos cuando fallan, reparando o sustituyendo las piezas o equipos estropeados. Estas técnicas quedaron obsoletas, ya que, si bien el programa de mantenimiento está centrado en solucionar el fallo cuando se produce, va a implicar altos costes por descenso de la productividad y mermas en la calidad.

De esta situación surge el mantenimiento predictivo, cuyo objetivo es evaluar la condición de salud de la máquina, y su evolución en el tiempo, mientras ella está funcionando. Esto evita que la máquina falle, deteniendo su funcionamiento de forma programada con el consiguiente ahorro de la pérdida de producción. Para determinar la condición de la máquina se evalúa una serie de síntomas que ella emite al exterior, de aquí es que a esta estrategia de mantenimiento también se le llame mantenimiento sintomático. Dentro de los síntomas que se analizan hay una gran variedad de ellos. Sin embargo, en la mayoría de las empresas el mantenimiento predictivo está centrado en el análisis de vibraciones más técnicas complementarias como el análisis de aceites, termografía, ultrasonido dentro de las más utilizadas [1].

2.1.2 Situación actual

El concepto de mantenimiento predictivo o mantenimiento basado en condiciones, comienza a ser aplicado por la industria a principios de la década de los ochenta. Aparecen los primeros equipos portátiles tipo “colector de datos” con memoria interna para la medición periódica en planta, y con interfases de conexión a los primeros PC disponibles. Pero, solamente hasta entrados los años noventa, se observa que el mantenimiento predictivo comienza a jugar un papel importante dentro de la industria. Las direcciones, comienzan a identificar la ventaja y necesidad de invertir en el desarrollo de un programa de mantenimiento predictivo [3].

2.1.3 Aplicación y metodología

El uso del mantenimiento predictivo consiste en establecer, en primer lugar, una perspectiva histórica de la relación entre la variable seleccionada y la vida del componente. Esto se logra mediante la toma de lecturas (por ejemplo la vibración de un cojinete) en intervalos periódicos hasta que el componente se rompa o se averíe.

Una vez determinada la factibilidad y conveniencia de realizar un mantenimiento predictivo a una máquina o línea, el paso siguiente es determinar las variables físicas a controlar que sean indicativas de la condición de la máquina. El objetivo de esta parte es revisar en forma detallada las técnicas comúnmente usadas en la monitorización según condición, de manera que sirvan de guía para su selección. La finalidad de la monitorización es obtener una indicación de la condición (mecánica) o estado de salud de la máquina, de manera que pueda ser operada y mantenida con seguridad y eficacia.

De acuerdo a los objetivos que se pretende alcanzar con la monitorización de la condición de una máquina debe distinguirse entre vigilancia, protección, diagnóstico y pronóstico.

- Vigilancia de máquinas: Su objetivo es indicar cuándo existe un problema. Debe distinguir entre condición buena y mala, y si es mala indicar su grado de severidad.
- Protección de máquinas: Su objetivo es evitar averías catastróficas. Una máquina está protegida si, cuando los valores que indican su condición llegan a valores considerados peligrosos, la máquina se detiene automáticamente.
- Diagnóstico de averías: Su objetivo es definir cuál es el problema específico y estimar cuánto tiempo más podrá funcionar la máquina sin riesgo de sufrir una avería.

2.1.4 Técnicas aplicadas al mantenimiento predictivo

Existen varias técnicas aplicadas para el mantenimiento predictivo entre las cuales destacan las siguientes [1], mostradas en la Ilustración 2:

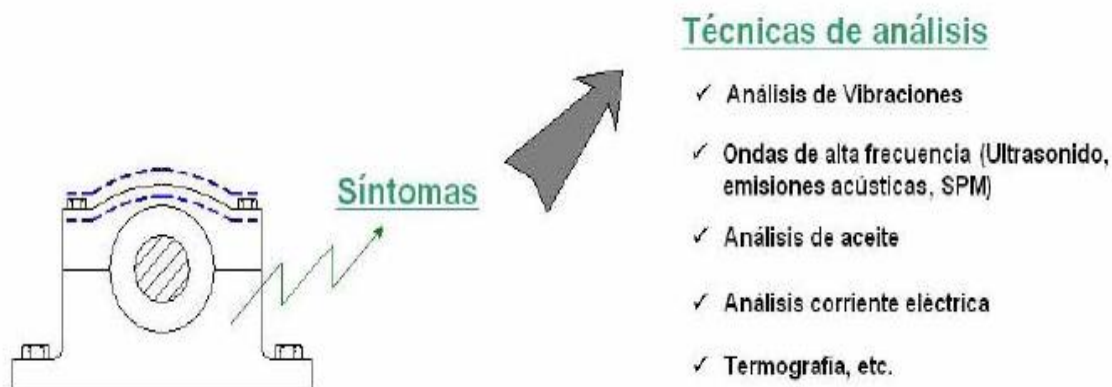


Ilustración 2: Diferentes técnicas utilizadas en el mantenimiento predictivo [2]

1. Análisis de vibraciones

El interés de las Vibraciones Mecánicas llega al Mantenimiento Industrial de la mano del Mantenimiento Preventivo y Predictivo, con el interés de alerta que implica un elemento vibrante en una máquina, y la necesaria prevención de las averías que conllevan las vibraciones a medio plazo. En las Ilustraciones 3 y 4 se observan una señal vibratoria y su transformada tiempo-frecuencia correspondiente.




Ilustración 3: Registro de vibraciones en un ciclo de trabajo en función del tiempo




Ilustración 4: Transformada Tiempo-Frecuencia

El interés principal para el mantenimiento deberá ser la identificación de las amplitudes predominantes de las vibraciones detectadas en el elemento o máquina, la determinación de las causas de la vibración y la corrección del problema que ellas representan. Las consecuencias de las vibraciones mecánicas son el aumento de los esfuerzos y las tensiones, pérdidas de energía, desgaste de materiales, y las más temidas: daños por fatiga de los materiales, además de ruidos molestos en el ambiente laboral...

Entre las razones más habituales por las que una máquina o elemento de la misma puede llegar a vibrar cabe destacar:

- Desequilibrio
- Desalineamiento
- Excentricidad
- Defectos en rodamientos y/o cojinetes
- Defectos en engranajes
- Defectos en correas
- Holguras
- Falta de lubricación

2. Análisis de lubricantes

Estos se ejecutan dependiendo de la necesidad, según:

- Análisis Iniciales: Se realizan a productos de aquellos equipos que presenten dudas provenientes de los resultados del Estudio de Lubricación y permiten correcciones en la selección del producto, motivadas por cambios en condiciones de operación.
- Análisis Rutinarios: Se aplican para equipos considerados como críticos o de gran capacidad, en los cuales se define una frecuencia de muestreo, siendo el objetivo principal de los análisis la determinación del estado del aceite, nivel de desgaste y contaminación entre otros.
- Análisis de Emergencia: se efectúan para detectar cualquier anomalía en el equipo y/o lubricante, según:
 - Contaminación con agua.
 - Presencia de partículas sólidas (filtros y sellos defectuosos).
 - Uso de un producto inadecuado.

La ilustración 5 muestra un análisis microscópico de lubricantes sintéticos para la detección de partículas sólidas metálicas.




Ilustración 5: Análisis de aceites. Presencia de partículas sólidas

3. Análisis por ultrasonidos

Este método estudia las ondas de sonido de alta frecuencia producidas por los equipos que no son perceptibles por el oído humano. En la Ilustración 6 se ve un ejemplo de análisis por ultrasonidos en el que se trata de localizar defectos en tuberías.



Ilustración 6: Análisis por ultrasonidos

Los ultrasonidos permiten detectar:

- Detección de fricción en máquinas rotativas.
- Detección de fallas y/o fugas en válvulas.
- Detección de fugas de fluidos.
- Pérdidas de vacío.
- Detección de "arco eléctrico".
- Verificación de la integridad de juntas de recintos estancos.

Casi todas las fricciones mecánicas, arcos eléctricos y fugas de presión o vacío producen ultrasonido en un rango aproximado a los 40 KHz. Estas son frecuencias con características muy aprovechables en el mantenimiento predictivo, puesto que las ondas sonoras son de corta longitud atenuándose rápidamente sin producir rebotes. Además, la alta direccionalidad del ultrasonido en 40 KHz permite localizar con rapidez y precisión la ubicación del defecto.

La aplicación del análisis por ultrasonido se hace indispensable especialmente en la detección de defectos existentes en equipos rotatorios que giran a velocidades inferiores a las 300 RPM, donde la técnica de medición de vibraciones se transforma en un procedimiento ineficiente.

4. Termografía

La termografía infrarroja es una técnica que permite, a distancia y sin ningún contacto, medir y visualizar temperaturas de superficie con precisión. La ilustración 7 muestra una Termografía de un interruptor eléctrico. En este campo son un método muy empleado



Ilustración 7: Análisis termográfico de un interruptor

Los ojos humanos no son sensibles a la radiación infrarroja emitida por un objeto, pero las cámaras termográficas son capaces de medir la energía con sensores infrarrojos, capacitados para "ver" en estas longitudes de onda. Esto nos permite medir la energía radiante emitida por los objetos y, por consiguiente, determinar la temperatura de la superficie a distancia, en tiempo real y sin contacto.

La gran mayoría de los problemas y averías en el entorno industrial, ya sea de tipo mecánico, eléctrico y de fabricación, están precedidos por cambios de temperatura que pueden ser detectados mediante la monitorización de temperatura con sistema de Termografía por Infrarrojos. Con la implementación de programas de inspecciones termográficas en instalaciones, maquinaria, cuadros eléctricos,... es posible minimizar el riesgo de una avería de equipos y sus consecuencias, a la vez que también ofrece una herramienta para el control de calidad de las reparaciones efectuadas.

El análisis mediante Termografía infrarroja debe complementarse con otras técnicas y sistemas de ensayo conocidos como pueden ser el análisis de lubricantes, el análisis de vibraciones, los ultrasonidos pasivos y el análisis predictivo en motores eléctricos.

5. Análisis eléctrico

El objeto del análisis eléctrico como técnica de mantenimiento predictivo es el de realizar estudios eléctricos sobre aquellos equipos que pueden presentar averías de origen electro-mecánico. En la Ilustración 8 se puede ver a un técnico de mantenimiento realizando un análisis eléctrico de equipos de bombeo.



Ilustración 8: Estudio de análisis eléctrico

En función de la corriente de alimentación, trifásica o continua, del equipo (generalmente motores eléctricos) que se desea analizar, se pueden verificar las siguientes condiciones:

- Estado del circuito
- Estado del aislamiento
- Estado del estator
- Estado del rotor
- Excentricidades en el entre-hierro

El análisis de corriente de un motor eléctrico puede desempeñarse a modo de control de calidad, como herramienta de tendencia o como emisor de un diagnóstico inmediato del estado del mismo.

2.1.5 Mantenimiento Pro-activo

En esta estrategia de mantenimiento se utiliza una variedad de tecnología para maximizar la vida de la máquina y eventualmente eliminar el mantenimiento reactivo. La parte principal de un programa pro-activo es identificar y corregir las causas raíz de la fallas en las máquinas. Una de las principales peculiaridades de una estrategia de mantenimiento pro-activo es que las técnicas utilizadas son una extensión natural de aquellas utilizadas en un programa de mantenimiento predictivo. En el capítulo 3 se ilustrarán estas ideas aplicándolas al caso de los rodamientos [2].

2.1.6 Conclusión

Es importante considerar que la productividad de una industria aumentará en la medida que las averías en las máquinas disminuyan de una forma sustancial en el tiempo. Para lograr lo anterior, resulta indispensable contar con la estrategia de mantenimiento más apropiada y con el personal capacitado tanto en el uso de las técnicas de análisis y diagnóstico de averías como también con conocimiento suficiente sobre las características de diseño y funcionamiento de las máquinas.

La principal razón porque las empresas no obtienen las significativas disminuciones en los costes de mantenimiento que debieran alcanzar al implementar una estrategia de mantenimiento predictivo-proactivo para sus máquinas es la falta de capacitación de su personal, y a esto contribuyen los siguientes factores:

- Solo recientemente algunas instituciones del mundo están capacitando a profesionales para ser médico de máquinas.
- Existe poco personal teórico-práctico que realice capacitación. Los que son solo teóricos no se ajustan a la realidad de los problemas que ocurren en terreno y los netamente prácticos son muy recetarios. Lamentablemente, las recetas no funcionan, la experiencia sin teoría no se puede transmitir.
- Se piensa equivocadamente que con una capacitación de una semana pueden convertir a un profesional en médicos de máquinas y además capacitado para diagnosticar en todo tipo de máquinas. Los médicos de personas estudian seis años para médico general más seis años para especializarse, y eso para diagnosticar problemas en una parte de una sola máquina: el ser humano.

2.2 Procesamiento de señales vibratorias

2.2.1 Introducción

El análisis de vibraciones es una de las prácticas más usadas del mantenimiento predictivo y requiere un conocimiento de las señales y su análisis es uno de los pilares fundamentales de la Ingeniería. La información que contienen las señales debe transformarse dependiendo de los propósitos de estudio.

En esta última década, se ha realizado un esfuerzo investigador notable para desarrollar técnicas de detección y diagnosis basadas en medidas vibratorias.

Estas técnicas se pueden aplicar en el dominio temporal, en el dominio de la frecuencia o en el dominio tiempo-frecuencia.

Los análisis más sencillos son aquéllos basados en medidas temporales. Estos sistemas emplean habitualmente medidas estadísticas efectuadas sobre las historias temporales, con el fin de establecer parámetros de tendencia que permitan de detectar la presencia de un modo de fallo.

Las técnicas basadas en análisis realizados en frecuencia utilizan como rasgos fundamentales para fijar medidas de tendencia las amplitudes de los armónicos dominantes en la respuesta, así como los anchos de banda asociados. Sin embargo, este tipo de análisis no es capaz de detectar fallos locales ya que la transitoriedad de estos eventos en el dominio temporal queda enmascarada en el espectro obtenido al realizar la transformación en frecuencia. Por consiguiente, el seguimiento tanto de los anchos de banda como de los armónicos afectados se ve, en caso de fallos locales, seriamente dificultado [6].

Una alternativa para resolver este problema se encuentra en el empleo de análisis tiempo-frecuencia, los cuales ofrecen una medida de la distribución de energía de la señal en ambos dominios simultáneamente (pero con distinta resolución de acuerdo con el principio de incertidumbre de Heisenberg). Dentro de estas técnicas se encuentran la transformada corta de

Fourier (STFT), las distribuciones Wigner-Ville y Choi-Williams y, por último, la transformada Wavelet. Esta última ha alcanzado bastante auge en la última década, por su capacidad para trabajar con transitorios y periodicidades [4].

2.2.2 Clasificación de las señales vibratorias

Desde el punto de vista de la cinemática las señales en general se dividen en dos grandes grupos: determinísticas (aquellas que representan fenómenos que pueden ser descritos analíticamente de manera exacta mediante una expresión matemática relativamente sencilla, y aleatorias o estocásticas (no es posible describirlas analíticamente con una expresión explícita simple como en el caso anterior. Sin embargo, cuando una señal estocástica se observa durante un largo periodo de tiempo puede verse cierta regularidad y puede ser descrita en términos de probabilidades y promedios estadísticos. La ilustración 9 muestra un esquema de clasificación de señales vibratorias.

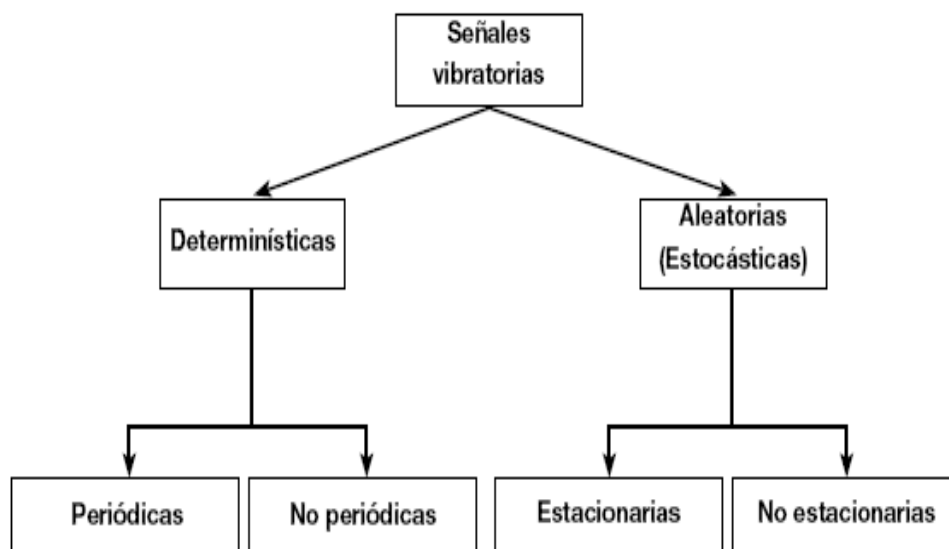


Ilustración 9: Clasificación de las señales vibratorias [6]

2.2.3 Modelo de procesamiento de señales vibratorias.

Para estudiar mejor las diferentes causas de las vibraciones en los sistemas debemos crear simples modelos dinámicos y matemáticos que los describen.

Sobre el comportamiento vibracional de los sistemas influyen tanto sus características constructivas como sus características de trabajo. Las vibraciones en los sistemas serán reflejo de su comportamiento dinámico. En la ilustración 10 se describe el proceso de adquisición, transformación y análisis de información empleado.

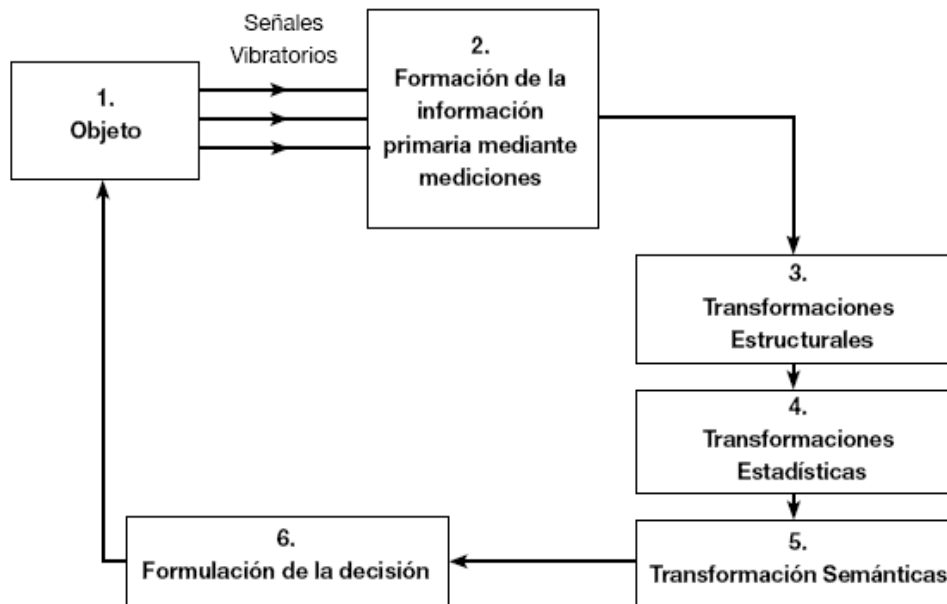


Ilustración 10: Esquema metodológico de la transformación de la información [6]

En el esquema de la ilustración 10, la información es una categoría abstracta pero siempre se presenta en forma de señales. La señal es la variación de un parámetro físico en función del tiempo y transporta cierta cantidad de información desde un emisor (la máquina objeto de estudio (1)) hasta un receptor (aparatos de medición) a través de los cuales se ejerce la primera transformación de las señales obtenidas (etapa 2). El ruido en las señales (la información inútil) se separa en las etapas 3, 4 y 5 a través de métodos técnicos. Las transformaciones estructurales en la información se llevan a cabo a través de normalización, cuantización y discretización, descomposición y sintetización.

2.2.4 Tipos de análisis de señales vibratorias

Nivel básico de diagnóstico de fallos

- **Análisis en frecuencia**

El análisis espectral es una herramienta clásica empleada en el análisis de fallos. Los primeros analizadores de espectros fueron analógicos y aparecieron a fines de los años 60, aunque todavía hay empresas que los siguen utilizando. Sin embargo, esto se masificó en las empresas con la aparición de los recolectores-analizadores digitales a inicios de los años 80.

La esencia del análisis espectral es descomponer la señal vibratoria medida con un sensor de vibraciones en sus componentes espectrales en frecuencia. Esto permite en el caso de las máquinas, correlacionar las vibraciones medidas generalmente en sus paradas, con las fuerzas dinámicas que actúan dentro de ella.

Este tipo de análisis puede ser útil cuando la máquina rotativa a analizar no contenga demasiados pasos de reducción, sin embargo su aplicación a máquinas más complejas deja de ser eficiente por el número de componentes a analizar; además, tiene el inconveniente de no indicar la localización del defecto [2].

- **Análisis de la forma de onda o de la vibración**

El análisis de la forma de la vibración u onda en el tiempo es un análisis complementario al análisis de espectros y para detectar algunos problemas específicos como impactos y transitorios es más efectivo que el anterior. Sin embargo, en una gran parte de problemas deberían ser usados integradamente

- **Análisis de la diferencia de fase de vibraciones.**

La diferencia de fase entre dos vibraciones de igual frecuencia se puede definir como la diferencia en tiempo o en grados con que ellas llegan a sus valores máximos, mínimos o cero. La fase de las vibraciones se mide normalmente respecto a un pulso de referencia obtenido de un fototacómetro.

Nivel medio. Análisis temporales-estadísticos

Se basan en la comparación de promedios síncronos (en determinado régimen de vueltas de la maquinaria) de una señal de referencia obtenida a priori cuando el par cinemático de engrane está “sano” (se tiene la certeza de que está sin ningún tipo de daño) frente a la señal obtenida en condiciones de funcionamiento de la máquina (funcionando en el mismo punto de operación).

Existen a su vez dentro de este tipo de análisis las siguientes subcategorías:

- **Técnicas de demodulación de amplitud y fase del residuo.**

Esta técnica se basa en un filtrado de la señal “pura” (sin tratar) alrededor de la frecuencia característica y de sus armónicos (hay que seleccionar un ancho de banda) para posteriormente sustraer dicho armónico fundamental y recuperar la envolvente de esta señal residual (tanto en amplitud como en fase) en el dominio temporal con el objetivo de captar el efecto fundamental anteriormente comentado de modulación de la señal como se puede ver en la ilustración 11.




Ilustración 11: Zoom y análisis de envolvente [9]

Hay que destacar que esta técnica es muy sensible a la selección del ancho de banda (si no se elige correctamente se puede llegar a perder cierta información de interés).

- **Análisis estadísticos.**

Se basan en realizar estadísticas sobre el residuo de la señal obtenida al sustraer la señal leída en condiciones operativas de la máquina respecto a la de referencia.

A grandes rasgos todas las técnicas anteriormente mencionadas tienen la ventaja de que al promediar se elimina parte del ruido “contaminante” de las señales; no obstante, hay que asegurar muy bien la sincronización puesto que de no ser así se podrían eliminar ciertos eventos periódicos que tuvieran relevancia en el dictamen de la diagnosis de la maquinaria rotativa.

Como ventaja cabe citar que los análisis temporales se han mostrado útiles tanto en la detección como en la localización del daño y además son sensibles a la evolución de la degradación.

- **Análisis de órbitas para el caso de ejes.**

La órbita es la forma como se mueve el centro del eje del rotor en un plano perpendicular a su eje. Se obtiene combinando los desplazamientos vibratorios captados por dos sensores ubicados relativamente entre ellos a 90° (por ejemplo en las direcciones horizontal y vertical respectivamente) [2]. La ilustración 12 nos muestra un ejemplo de un eje desequilibrado con tres estados de carga diferentes y los resultados del análisis de órbitas.




Ilustración 12: Órbitas rotor desbalanceado con y sin precargas [9].

Nivel avanzado de diagnóstico de fallas.

- **Transformadas tiempo-frecuencia.**

El análisis espectral clásico es adecuado para analizar vibraciones compuestas de ciertos componentes estacionarios durante su periodo de análisis. Esto indica que si se producen efectos transitorios en la vibración, éstos se promedian en el periodo de análisis, perdiéndose toda información sobre la naturaleza o forma de estas variaciones. Existe entonces la necesidad de un análisis que describa mejor señales no estacionarias o transitorias. Esto se consigue con las distribuciones o transformadas tiempo-frecuencia.

Las transformadas tiempo-frecuencia son análisis tridimensionales amplitud-tiempo-frecuencia, es decir, se agrega una nueva dimensión, el tiempo, a la clásica FFT. Existen varios tipos de transformadas tiempo-frecuencia, las cuales se pueden clasificar en lineales y no lineales. Dentro de las primeras las más conocidas son la transformada corta de Fourier (*Short Fast Fourier Transform*) y las Wavelets. Dentro de las no lineales están la pseudo transformada de Wigner-Ville, la Choi-Williams, la

transformada ZAM [12]. Estas transformadas se están implementando actualmente en algunos analizadores de vibraciones comerciales debido a que su uso no se aplica de forma directa como con la FFT. Se requiere para su uso gran conocimiento del usuario y dependiendo del problema a analizar es más útil usar una u otra transformada.

En el capítulo 2.3 y 2.4 se amplía esta información ya que son los métodos que emplearemos para procesar nuestras señales vibratorias.

- **Análisis espectral con seguimiento de orders**

En el análisis espectral clásico cada componente espectral se asocia a una fuerza dinámica que la genera.

Este análisis es por lo tanto adecuado a vibraciones estacionarias. Cuando es aplicado a máquinas que trabajan a velocidad variable, las componentes espectrales se dispersan en el espectro haciendo imposible su análisis.

Este proceso se puede realizar a través de dos técnicas: muestreo directo por hardware y re-muestreo por software (se adquiere la vibración y un pulso de referencia de un tacómetro a intervalos de tiempo constante y luego por software se realiza el re-muestreo a intervalos de ángulo constante). Una vez realizado este proceso se aplica la tradicional FFT. Con esto se cambia el dominio frecuencial por el dominio en orders. [2]

2.3 La Transformada de Fourier o FT (Fourier Transform)

La idea básica de las series de Fourier es que toda función periódica de periodo T puede ser expresada como una suma trigonométrica de senos y cosenos del mismo periodo T.

En Ingeniería la transformada de Fourier se utiliza para pasar al dominio frecuencial una señal para así obtener información que no es evidente en el dominio temporal. Se demuestra matemáticamente que una señal periódica se puede descomponer en una suma de senos y cosenos formando una base ortogonal, de esta forma, señales como la voz o las ondas se pueden descomponer en un sumatorio de señales trigonométricas. El conjunto de constantes que multiplican a cada frecuencia forman el espectro de frecuencias. De esta forma se pueden llegar a diversos experimentos muy interesantes [10]:

1. La voz humana recorre el espectro de los 100Hz a los 5.000Hz y el oído humano se encuentra entre los 20 Hz y los 20.000 Hz.
2. Si conocemos la densidad espectral de un sistema y la entrada podemos conocer la densidad espectral de la salida. Esto es muy útil para el diseño de filtros de radiotransistores.
3. La transformada de Fourier también se utiliza en el ámbito del tratamiento digital de imágenes, como por ejemplo para mejorar o definir más ciertas zonas de una imagen fotográfica o tomada con una computadora.

Sea $x(t)$ una señal continua. Se define la transformada de Fourier de x , denotada con $X(\omega)$, como la función:

$$X(\omega) = \int_{-\infty}^{\infty} x(t)e^{-j\omega t} dt$$

(Ec. 2.3.1)

En la ilustración 13 se puede apreciar un ejemplo de la señal “y” y su transformada de Fourier:




Ilustración 13: Representación de FFT de una señal [3]

Se ha alcanzado un gran éxito aplicando la transformada de Fourier en el procesamiento de señales estacionarias ya que somos capaces de determinar el espectro de frecuencias de la señal, y con él, las frecuencias fundamentales que aparecen en una señal. Si somos capaces de entender a qué corresponden, seremos capaces de clasificar defectos sin necesidad de un potente sistema de clasificación.

Sin embargo el problema de esta transformada surge a la hora de analizar señales transitorias en las que el espectro de frecuencias no es el mismo en cada instante de tiempo. En este caso nos encontraríamos ante el dilema de que existirían infinitos espectros de frecuencias para una única representación temporal. De modo que si representamos la señal en el dominio del tiempo no tenemos información sobre la frecuencia y si localizamos la señal en el dominio de la frecuencia perdemos por completo la información temporal.

La Transformada Corta de Fourier

Como primera solución se desarrolló la Transformada Corta de Fourier denominada STFT (*Short Term Fourier Transform*). La idea básicamente consiste en dividir la señal en pequeños espacios temporales en los cuales seamos capaces de calcular el espectro de frecuencias de cada uno de ellos [11]. Se puede ver un ejemplo de la STFT en la ilustración 14.

Sus principales inconvenientes aparecen a la hora de elegir el tamaño de la ventana (el tamaño del diferencial temporal). Si lo que se desea es obtener una resolución grande en el espacio temporal elegiremos una ventana de poca longitud, a costa de dispersar la distribución espectral, no pudiendo conocer con exactitud sus componentes. Por el contrario, la elección de una ventana grande nos permitirá conocer los componentes frecuenciales a costa de perder información del momento en el que ocurren.




Ilustración 14: Representación de STFT de una señal musical [3]

Como solución a estos problemas de tamaño de la ventana existen métodos más modernos que la STFT como la Transformada Wavelet de la cual hablaremos en el siguiente punto.

2.4 La transformada Wavelet

2.4.1 Introducción

El análisis wavelet es una herramienta matemática que descompone una señal temporal en suma de diferentes señales temporales denominadas funciones wavelets hijas. Cada una de estas tiene diferentes escalas en diferentes niveles de resolución obtenidos mediante escalado y dilatación de una determinada función matemática temporal denominada función wavelet madre [12].

La wavelets son familias de funciones definidas por:

$$h_{a,b} = \frac{h\left(\frac{x-b}{a}\right)}{\sqrt{|a|}}; a, b \in \mathbb{R}, a \neq 0$$

(Ec. 2.1)

y son generadas a partir de funciones madre $h(x)$. A esa función madre se le agregan coeficientes que son la escala (a) que permite hacer dilataciones y contracciones de la señal y la variable de traslación (b), que nos permite mover a la señal en el tiempo. Estas variables son números reales y obviamente para una escala de 0 la función queda indeterminada.

Existen diferentes wavelets madre que ya son utilizadas de forma constante y que tienen definiciones establecidas. Sin embargo, la elección de un tipo de wavelet depende de la aplicación específica que se le vaya a dar. Las mas empleadas en la actualidad se muestran en la Ilustración 15.

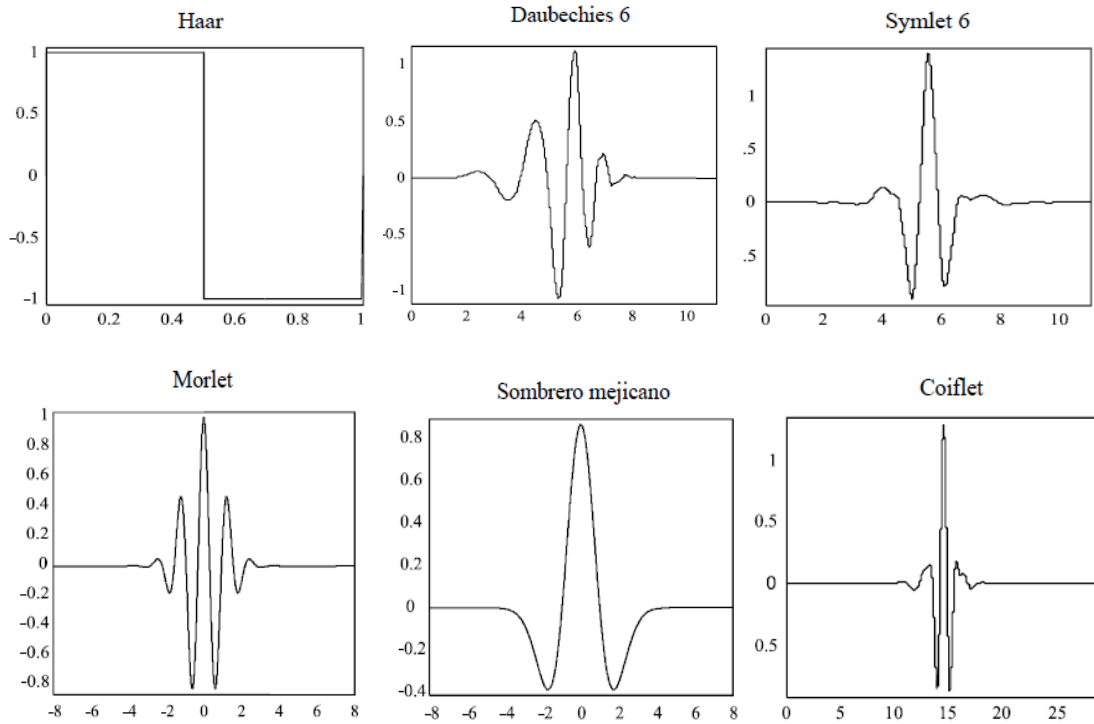


Ilustración 15: Wavelets madre más empleadas

Las Transformadas Wavelets comprenden la Transformada Continua de Wavelets y la Transformada Discreta de Wavelets. Estas son las herramientas matemáticas que permiten el análisis de señales de manera muy similar a como lo hacen las Transformadas de Fourier, dando información en el dominio del tiempo y en el dominio de la frecuencia.

2.4.2 Transformada Wavelet Continua (CWT)

Para hacer el análisis de una señal vamos a multiplicar cada punto de dicha señal por la wavelet madre que se haya elegido, cuyas características de escala y traslación serán permanentes para todo el proceso, después cada una de las muestras que se obtienen se van a sumar y de este modo tendremos la señal traslada del dominio del tiempo al dominio de la frecuencia y el tiempo. Este proceso es el mismo que utiliza la Transformada Corta de Fourier (STFT) [13].

$$CWT(a, b) = \frac{1}{\sqrt{|a|}} \int h\left(\frac{x-b}{a}\right) f(x) dx ; a, b \in \mathbb{R}, a \neq 0$$

(Ec. 2.2)

donde a es la escala y b es la traslación, ambos números reales, y $f(x)$ es la función a analizar. La variable de escala a puede ser vista como $a = \frac{f_0}{f}$ donde f_0 denota la frecuencia central de la wavelet. De esta manera tendremos que la ecuación 2.2 se puede expresar también de la siguiente manera:

$$CWT(b, f) = \sqrt{\left|\frac{f}{f_0}\right|} \int h\left(\frac{f}{f_0}(x-b)\right) f(x) dx ; f, b \in \mathbb{R}, a \neq 0$$

(Ec. 2.3)

Esta transformada permite la representación de la señal $f(x)$ en el plano tiempo-escala.

A continuación se va a explicar como la CWT transforma la señal de un dominio a otro que depende de dos variables. La variable de escala lleva en si la información de la dilatación y la contracción de la señal, pero podría verse desde otro punto de vista donde lo que cambia es la frecuencia y con ello al dilatarse la frecuencia se reduce y al contraerse la frecuencia aumenta. Aquí es justamente donde se aprovecha esta característica de las *wavelets* para obtener la información de la señal y conocer sus componentes de frecuencia.

En el dominio del tiempo el análisis es más sencillo ya que la variable de traslación tiene la información de tiempo, pues nos indica en qué lugar del eje del tiempo se encuentra la *wavelet*. De este modo se van completando los datos en forma de una matriz, donde para cada integral que resolvamos tendremos un punto del plano traslación-escala, que es equivalente a tener la información en el plano tiempo-frecuencia.

En la Ilustración 16 vemos perfectamente cómo trabaja la CWT así como sus variables a partir de una señal sinusoidal de frecuencia variable.

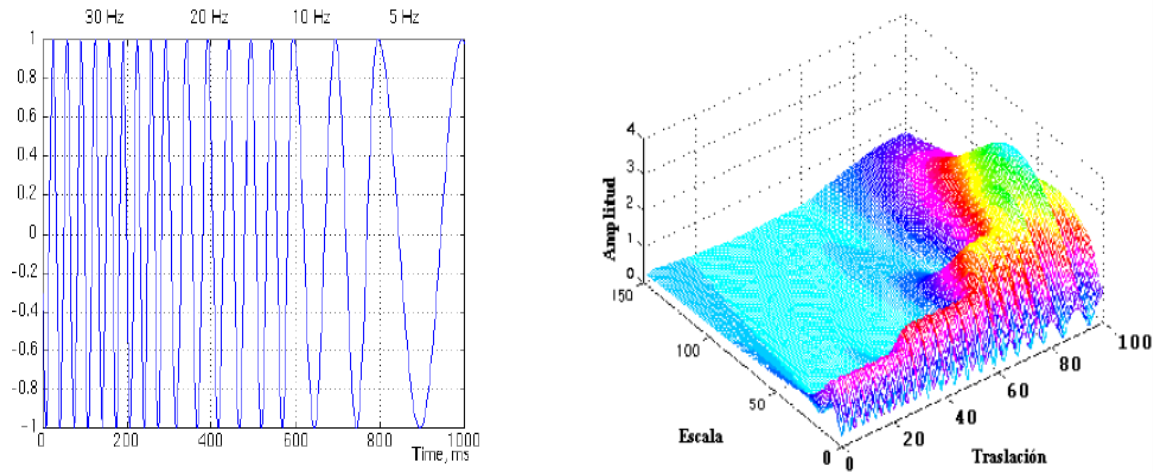


Ilustración 16: Señal sinusoidal y su transformada wavelet [7]

2.4.3 La Transformada Wavelet Discreta (DWT)

Para el tratamiento de señales discretas empleamos wavelets discretas, cuyos parámetros de escala y traslación son elegidos tal que en el nivel j la wavelet $a_0^j h(a_0^{-j}x)$ es a_0^j veces el ancho de $h(x)$. Esto significa que el parámetro de escala es $a = a_0^j: j \in \mathbb{Z}$ y el parámetro de traslación $b = kb_0 a_0^j: j, k \in \mathbb{Z}$, siendo a y b los coeficientes mencionados en las ecuaciones anteriores. De este modo la familia de wavelets está dada por [13]:

$$h_{j,k} = a_0^{-\frac{j}{2}} h(a_0^{-j}x - kb_0) \quad (\text{Ec. 2.4})$$

Así, la Transformada Wavelet Discreta tiene la forma

$$d_{j,k} = a_0^{-\frac{j}{2}} \int f(x) h(a_0^{-j}x - kb_0) dx \quad (\text{Ec. 2.5})$$

De lo anterior surge un concepto importante que es el Análisis Multiresolución (MRA) [15] que, como dice su propio nombre es un análisis de la señal a estudiar de tal modo que cada componente de frecuencia es analizado con una resolución diferente. Esto es una alternativa más sobre la STFT que analiza todas las componentes de frecuencia a una misma resolución dada. En general, las ventajas que ofrece este método es que, con el uso de *wavelets*, a altas frecuencias se tiene una buena resolución en tiempo y poca resolución en frecuencia, mientras que para bajas frecuencias los resultados son buena resolución en frecuencia y poca resolución en tiempo.

La Ilustración 17 nos muestra que los ejes que se manejan son tiempo y frecuencia, aquí se ejemplifica lo que se mencionó anteriormente. Cabe señalar que para la STFT las ventanas serían de igual dimensión para todos los casos ya que la función utilizada para ese análisis no se dilata ni se contrae, lo que representa una ventaja de la DWT sobre la STFT, ya que se puede tener mayor detalle del comportamiento de la señal, dada la resolución que puede alcanzar.

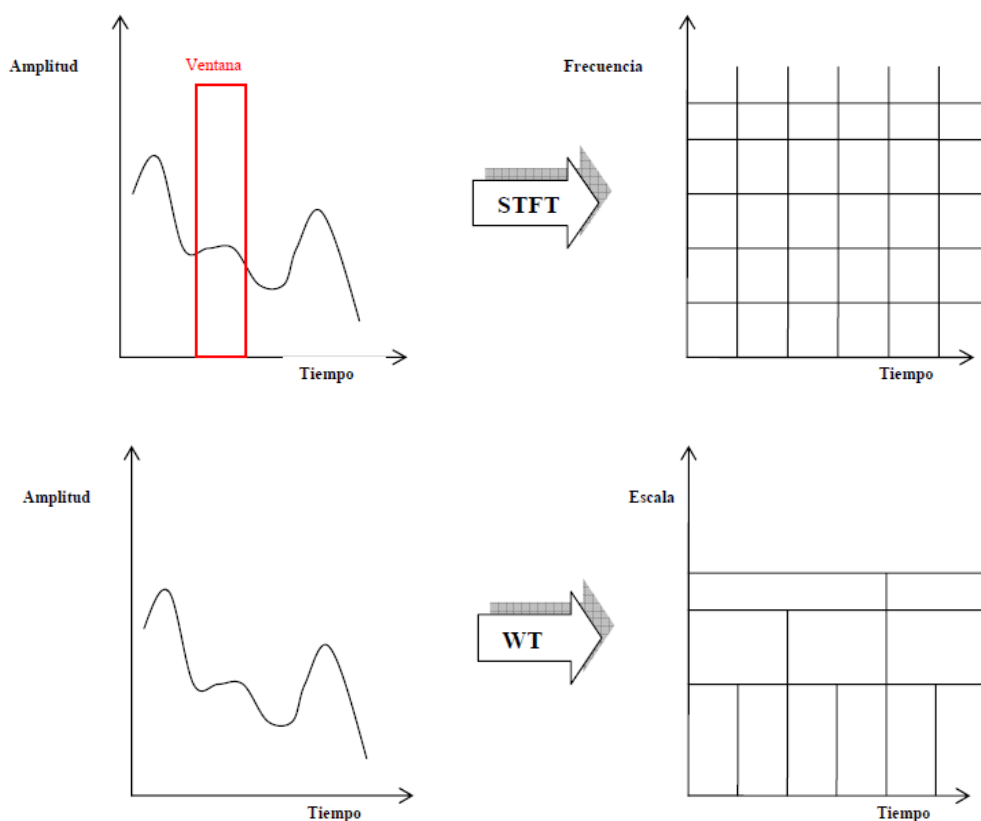


Ilustración 17: Comparación de la ventana de transformación de una STFT y una WT [14]

El muestreo que se utiliza está basado en el Análisis Multiresolución (MRA) y se realiza en base una serie de filtros paso alto y filtros paso bajo. De este modo se van obteniendo las muestras de bajas y altas frecuencias. Para esta labor se han empleado un par de términos importantes que son el decimado y undecimado, que propiamente se refieren al sentido en el que se realiza el muestreo. El decimado se refiere a incrementar en número de muestras, mientras que el undecimado se refiere a reducir el número de las mismas.

A partir de estos conceptos podemos explicar el proceso que se realiza para transformar una señal al dominio de tiempo y frecuencia. El proceso consiste en una serie de filtrados repetitivos usando el concepto de decimado, es decir, al principio se emplea un filtro paso bajo y

otro paso alto con frecuencia de corte de la mitad de la máxima componente de frecuencia de la señal a analizar.

Posteriormente el resultado se vuelve a filtrar bajo las mismas características, la frecuencia de corte del segundo filtro es la mitad de la máxima componente de frecuencia de la señal que va a entrar a ese filtro, de este modo el proceso se repite y la salida de cada filtro va generando un par de muestras más a las que se tenían inicialmente. Este proceso se realiza de este modo, ya que como se está trabajando con una señal discretizada no se podría realizar el mismo proceso que se hizo con la transformada continua. El siguiente paso es explicar cómo se obtiene la información de tiempo y frecuencia en este caso.

El resultado es la descomposición de cada paquete en dos, el detalle o coeficientes wavelet (D) y las aproximaciones o coeficientes de escala (A), quedando la descomposición como se muestra en la ilustración 18 [15].

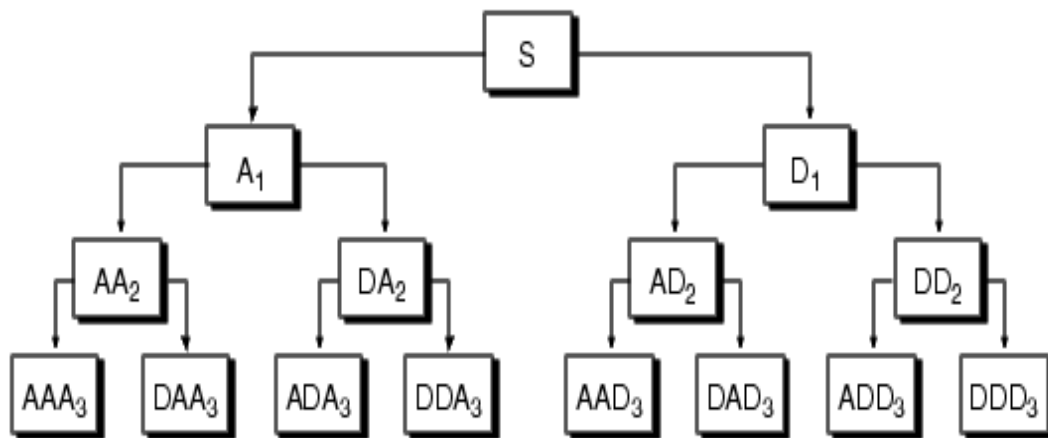


Ilustración 18: Árbol de descomposición wavelet

2.4.4 Energía de señales de vibración

En una señal de vibración que varía su amplitud con respecto al tiempo, tal como muestra la siguiente figura, existen partes positivas y negativas. Si analizamos el área bajo la curva, nos indicaría datos probablemente muy pobres debido a las áreas se estarían restando a lo largo del intervalo de integración como se aprecia en la ilustración 19 [7].




Ilustración 19: (a) Señal temporal $x(t)$, (b) Energía de la señal $x(t)$,

Sin embargo, si tomamos el cuadrado de la señal nos aseguráramos de que todos los valores a analizar fuesen positivos. De hecho, Un indicador común en el mundo de

procesamiento de señales es tomar el cuadrado de los valores de tal función, lo que se llamaría la energía E_s de una señal continua $x(t)$, tal como se detalla en la siguiente ecuación.

$$E_s = \langle x(t), x(t) \rangle = \int_{-\infty}^{\infty} |x(t)|^2 dt \quad (\text{Ec. 2.4.1.6})$$

Por otra parte, también existe el concepto de densidad de energía espectral $E_s(f)$ de una señal $x(t)$, dada por la ecuación:

$$E_s(f) = |X(f)|^2 \quad (\text{Ec. 2.4.1.7})$$

Donde $X(f)$ es la Transformada de Fourier de $x(t)$

En cuanto se refiere al ámbito experimental, las señales de vibración son de naturaleza discreta, por lo que las ecuaciones podrían tomar otra forma de acuerdo al caso que nos ocupa en este PFC.

De forma discreta, la ecuación (Ec. 2.4.1.8) puede representarse como sigue:

$$E_s[x] = \sum_K x_k^2 \quad (\text{Ec. 2.4.1.8})$$

Para una señal $x[k]$

Donde k pertenece a \mathfrak{R} y representa el número de muestras de la señal de un total de K muestras.

Cuando se realiza la descomposición en *Wavelet Paquet* de una señal, se generan nuevos paquetes que contienen distintos rangos de frecuencia dependiendo del rango de frecuencia inicial de la señal y del nivel de descomposición deseado. Si se desea analizar la energía de los paquetes wavelet resultantes, se debe recurrir a la siguiente ecuación:

$$E_{n,j}[x] = \sum_K x_{j,n,k}^2 \quad (\text{Ec. 2.4.1.9})$$

Esta ecuación representa el cálculo de energía de un paquete wavelet n , a través de la sumatoria de los cuadrados de las k -ésimas muestras del total (K) de muestras al nivel j de descomposición.

2.4.5 Aplicaciones

La Teoría de *Wavelets* tiene muchas aplicaciones reales que comprenden la detección de discontinuidades y puntos de ruptura en las señales, la identificación de frecuencias puras, la reducción de ruido en señales, la compresión de señales, aproximación de funciones, métodos espectrales para resolver ecuaciones diferenciales, análisis de fluidos turbulentos, entre otros.

2.5 Redes Neuronales Artificiales (RNA's)

2.5.1 Introducción

El estudio de las redes neuronales artificiales forma parte de una rama que se engloba dentro del campo de la inteligencia artificial. Dicha rama se dedica al estudio y desarrollo de simulaciones de los elementos inteligentes de la naturaleza (cerebros) con el fin de que, de forma espontánea, estas simulaciones (redes neuronales) se comporten de forma inteligente.

Si comparamos una neurona real con una artificial como en la ilustración 20 observamos que disponen la misma configuración: un cuerpo al que le llega información del resto de neuronas por las dendritas (entrada) y que envía información a otras por el axón (salida) [18].




Ilustración 20: Comparación entre neurona biológica y neurona artificial [3]

2.5.2 Elementos básicos que componen una red neuronal

Una red neuronal típica está compuesta por múltiples neuronas, que a su vez se componen de una función de entrada o de base, una función de activación y una función de salida, como muestra la ilustración 21 [17].

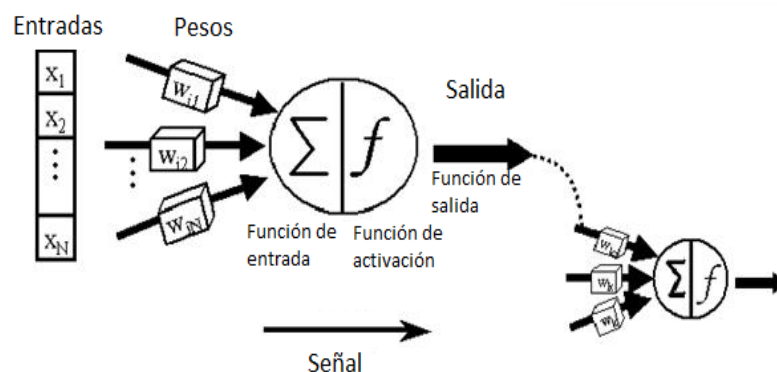


Ilustración 21: Estructura básica de una neurona

- Función de entrada

Cada nodo, suministra un valor y_j a su salida. Este valor se propaga a través de la red mediante conexiones hacia otros nodos de la red. Asociada a cada conexión hay un peso sináptico denominado w_{ij} , que determina el efecto del nodo j -ésimo sobre el nodo i -ésimo. Las entradas al nodo i -ésimo que provienen de los otros nodos son acumulados junto con el valor umbral θ_i , y se aplica la función base f , obteniendo u_i .

Las principales funciones de entrada que nos podemos encontrar en una red neuronal artificial son:

- Sumatoria:

$$u_i(w, x) = \sum_{j=1}^n w_{ij} x_j$$

- Productoria

$$u_i(w, x) = \prod_{j=1}^n w_{ij} x_j$$

- Máximo

$$u_i(w, x) = \text{Max}(w_{ij} x_j)$$


- Hiperesférica

$$u_i(w, x) = \sqrt{\sum_{j=1}^n (w_{ij} - x_j)^2}$$

- Función de activación

En biología, una neurona puede encontrarse en un estado de excitación (activa) o de no excitación (inactiva). Del mismo modo las neuronas artificiales también tienen diferentes estados de activación. Algunas, al igual que las biológicas, solo dos, pero otras pueden tomar cualquier valor dentro de un rango determinado. El estado de actividad de una neurona se calcula mediante la función activación, transformando la entrada global (menos el umbral, θ_i) en un valor de activación. La función activación, es una función de la entrada global (gin_i) menos el umbral (θ_i). Las funciones de activación más comúnmente utilizadas se detallan a continuación [19]:

- Función lineal




$$f(x) = \begin{cases} -1 & x \leq -1/a \\ a * x & -1/a < x < 1/a \\ 1 & x \geq 1/a \end{cases}$$

$$\text{con } x = gin_i - \theta_i, \text{ y } a > 0.$$


Los valores de salida obtenidos por medio de esta función de activación serán: $a \cdot (gin_i - \theta_i)$, cuando el argumento de $(gin_i - \theta_i)$ esté comprendido dentro del rango $(-1/a, 1/a)$. Por encima o por debajo de esta zona se fija la salida en -1 o 1, respectivamente. Cuando $a = 1$ (siendo que la misma afecta la pendiente de la gráfica), la salida es igual a la entrada.

- Función logarítmico sigmoidea




Los valores de salida que proporciona esta función están comprendidos dentro de un rango que va de 0 a 1. Al modificar el valor de g se ve afectada la pendiente de la función de activación.

- Función tangente hiperbólica sigmoidea



Los valores de salida de la función tangente hiperbólica están comprendidos dentro de un rango que va de -1 a 1. Al modificar el valor de g se ve afectada la pendiente de la función de activación.

- Función en base radial



Empleada en redes neuronales de base radial, son funciones gaussianas que se ajustarán durante el proceso de entrenamiento hasta obtener las funciones que relacionen mejor las inputs con sus targets.

- Función de salida


El último componente que una neurona necesita es la función de salida. El valor resultante de esta función es la salida de la neurona i (out_i). La función de salida determina que valor se transfiere a las neuronas vinculadas. Si la función de activación está por debajo de un umbral determinado, ninguna salida se pasa a la neurona subsiguiente. Normalmente, no cualquier valor es permitido como una entrada para una neurona, por lo tanto, los valores de salida están comprendidos en el rango $[0, 1]$ o $[-1, 1]$. Las funciones de salida más comunes son:

- Ninguna

La salida es la misma que la entrada.

- Binaria

Puede ser de la forma $[0, 1]$ o $[-1, 1]$.



El resultado final es un conjunto de capas de neuronas agrupadas en capas tres tipos de capas que forman la red neuronal, como se aprecia en la ilustración 22.




Ilustración 22: Esquema básico de una red neuronal

2.5.3 Niveles o capas de una red neuronal.

La distribución de neuronas dentro de la red se realiza formando niveles o capas, con un número determinado de dichas neuronas en cada una de ellas. A partir de su situación dentro de la red, se pueden distinguir tres tipos de capas:

- De entrada: es la capa que recibe directamente la información proveniente de las fuentes externas de la red.
- Ocultas: son internas a la red y no tienen contacto directo con el entorno exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de las capas ocultas pueden estar interconectadas de distintas maneras, lo que determina, junto con su número, las distintas topologías de redes neuronales.
- De salidas: transfieren información de la red hacia el exterior.

2.5.4 Clasificación de las redes neuronales artificiales

Podemos clasificar las RNA de acuerdo con la dirección de la conexión de sus neuronas, pudiendo encontrar redes feedforward o redes feedback.

Las redes feedforward se caracterizan porque las interconexiones de sus neuronas son siempre unidireccionales, al contrario que en las redes feedback, en las que hay enlaces de capas posteriores hacia capas anteriores. Las redes feedforward se denominan también estáticas porque con una entrada determinada producen una única salida, no se comportan como memorias, esto es, la respuesta no es función de estados previos. Por esta razón se las compara en ocasiones con circuitos combinacionales.

Por su parte, las redes feedback se llaman también recurrentes o dinámicas por la razón contraria: pueden tener bucles y su salida resulta de una evolución a través de una serie de estados tras la presentación de la entrada. Se las compara, pues, con circuitos secuenciales.

En el esquema de la ilustración 23 se muestran algunos de los distintos tipos de redes neuronales artificiales existentes, agrupadas en cuanto a su pertenencia a la categoría de feedforward o feedback.

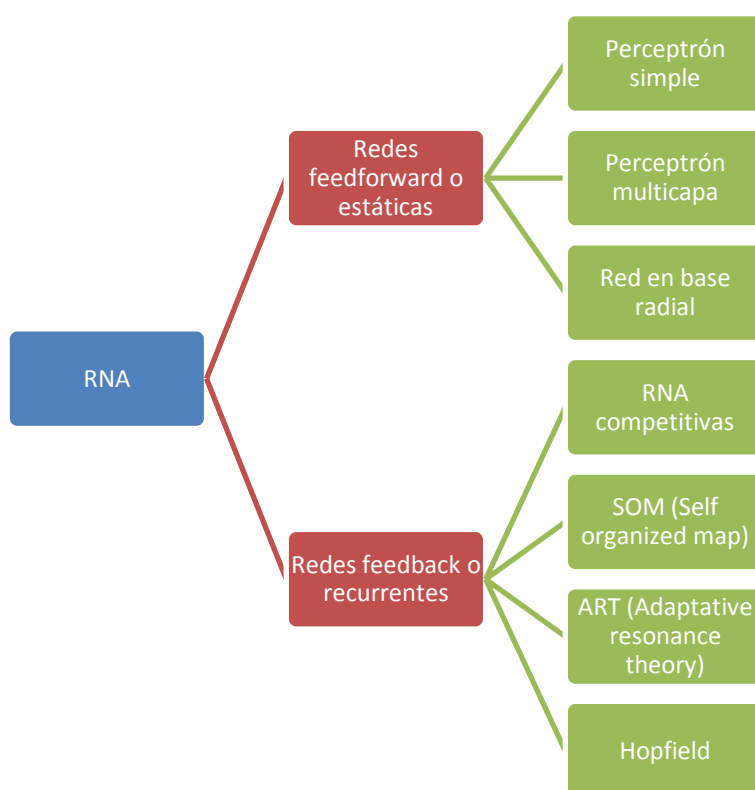


Ilustración 23: Clasificación de las redes neuronales

En nuestro caso emplearemos redes perceptrón multicapa y redes en base radial como ejemplo de feedforward, y redes SOM como muestra de feedback.

2.5.5 Mecanismos de aprendizaje

Una red neuronal debe aprender a calcular la salida correcta para cada entrada en el conjunto de ejemplos. Este proceso de aprendizaje se denomina proceso de entrenamiento o

acondicionamiento. El conjunto de datos sobre el cual este proceso se basa es llamado conjunto de datos de entrenamiento.

La topología de la red y las diferentes funciones de cada neurona (entrada, activación y salida) no pueden cambiar durante el aprendizaje, mientras que los pesos sobre cada una de las conexiones si pueden hacerlo. El aprendizaje de una red neuronal significa adaptación de los pesos. Por tanto se puede afirmar que el proceso de aprendizaje termina cuando los valores de los pesos permanecen estables.

Así podemos destacar dos métodos de aprendizaje: el aprendizaje supervisado y el no supervisado [18].

- Aprendizaje supervisado

Se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (targets) que determina la respuesta que debería generar la red a partir de una entrada determinada. El agente controla la salida de la red y en caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada.

En este tipo de aprendizaje se suelen considerar, a su vez, tres formas de llevarlo a cabo, que dan lugar a los siguientes aprendizajes supervisados:

- Aprendizaje por corrección de error: Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos a la salida de la red, es decir, en función del error cometido en la salida.
- Aprendizaje por refuerzo: Se trata de un aprendizaje supervisado, más lento que el anterior, que se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir, de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada.

En el aprendizaje por refuerzo la función del supervisor se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada (éxito = +1 o fracaso = -1), y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades. Se podría decir que en este tipo de aprendizaje la función del supervisor se asemeja más a la de un crítico (que opina sobre la respuesta de la red) que a la de un maestro (que indica a la red la respuesta concreta que debe generar), como ocurría en el caso de supervisión por corrección del error.

- Aprendizaje estocástico: Consiste básicamente en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.

- Aprendizaje no supervisado

Las redes con aprendizaje no supervisado no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta.

Estas redes deben encontrar las características, regularidades, correlaciones o categorías que se puedan establecer entre los datos que se presenten en su entrada.

En cuanto a los algoritmos de aprendizaje no supervisado, en general se suelen considerar dos tipos, que dan lugar a los siguientes aprendizajes:

- Aprendizaje hebbiano: Esta regla de aprendizaje es la base de muchas otras, la cual pretende medir la familiaridad o extraer características de los datos de entrada. El fundamento es una suposición bastante simple: si dos neuronas N_i y N_j toman el mismo estado simultáneamente (ambas activas o ambas inactivas), el peso de la conexión entre ambas se incrementa.
- Aprendizaje competitivo y comparativo: Se orienta a la clusterización o clasificación de los datos de entrada. Como característica principal del aprendizaje competitivo se puede decir que, si un patrón nuevo se determina que pertenece a una clase reconocida previamente, entonces la inclusión de este nuevo patrón a esta clase matizará la representación de la misma. Si el patrón de entrada se determinó que no pertenece a ninguna de las clases reconocidas anteriormente, entonces la estructura y los pesos de la red neuronal serán ajustados para reconocer la nueva clase.

2.5.6 Topología de las redes neuronales

Redes de Hopfield

Hopfield comienza a trabajar en el modelo que después llevaría su nombre alrededor de 1985. Estas redes son bastante parecidas al modelo del Perceptrón, pero presentan una característica adicional: las neuronas en la capa oculta, presentan conexiones de salida hacia otras neuronas de la capa oculta. Además, cada neurona de la capa de entradas está conectada con una neurona de la capa oculta, y cada neurona de la capa oculta emite una sola conexión hacia la capa de salidas. Y estas conexiones (capa de entradas - capa oculta, y capa oculta - capa de salidas) no implican cálculo de pesos sinápticos ni de valores umbral. En la ilustración 24 puede verse la topología de una red de Hopfield. Las características generales de las redes Hopfield son [21]:

- Una única capa oculta (construida y posteriormente entrenada).
- Interconexión completa, realimentación.
- Respuesta dinámica: la red progresa con la entrada hasta alcanzar un estado estable (hasta que la salida deja de cambiar).
- Aplicaciones: reconocimiento de patrones, almacenados en sus pesos sinápticos.

Redes Perceptrón Multicapa

El perceptrón multicapa es una red neuronal artificial formada por múltiples capas. Esto le permite resolver problemas que no son linealmente separables, lo cual es la principal limitación del perceptrón. El perceptrón multicapa puede ser totalmente o localmente conectado. Su topología está compuesta por una capa de entrada, una o varias capas ocultas y una capa de salida, como muestra la ilustración 26.

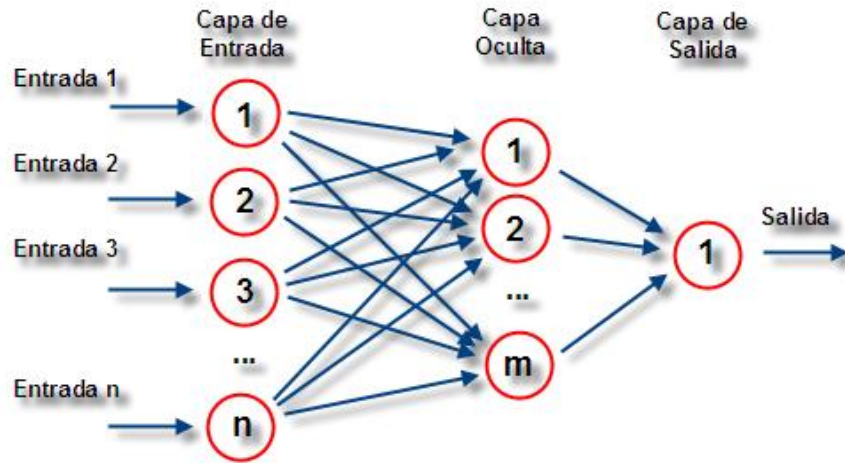


Ilustración 26: Topología de una red perceptrón multicapa

Las capas se diferencian por:

- Capa de entrada: Constituida por aquellas neuronas que introducen los patrones de entrada en la red. En estas neuronas no se produce procesamiento. Existe una neurona por cada señal introducida.
- Capas ocultas: Formada por aquellas neuronas cuyas entradas provienen de capas anteriores y cuyas salidas pasan a neuronas de capas posteriores.
- Capa de salida: Neuronas cuyos valores de salida se corresponden con las salidas de toda la red.

Redes de Base Radial

Las redes de base radial son una clase especial de redes feedforward, con tres capas generalmente (entrada, oculta, salida) [20].

Las neuronas de la capa oculta usan como función de activación una función de base radial (por ejemplo, la función de Gauss), por tanto, tenemos tantas funciones de base radial como neuronas tenga la capa oculta, con centro y longitud definidas por su vector de pesos asociado. La última capa realiza una interpolación, de modo que una red de base radial lo que hace es buscar una función que se ajuste al espacio de patrones de entrada.

Su aprendizaje, como decimos, es híbrido, y su convergencia es muy rápida (más aún que la de redes como las *backpropagation*), aunque necesitan muchos elementos de procesado en la capa oculta para obtener una buena interpolación, lo que hace que sus requisitos computacionales sean elevados.

La ilustración 27 representa la topología de una red de base radial integrada en Matlab.

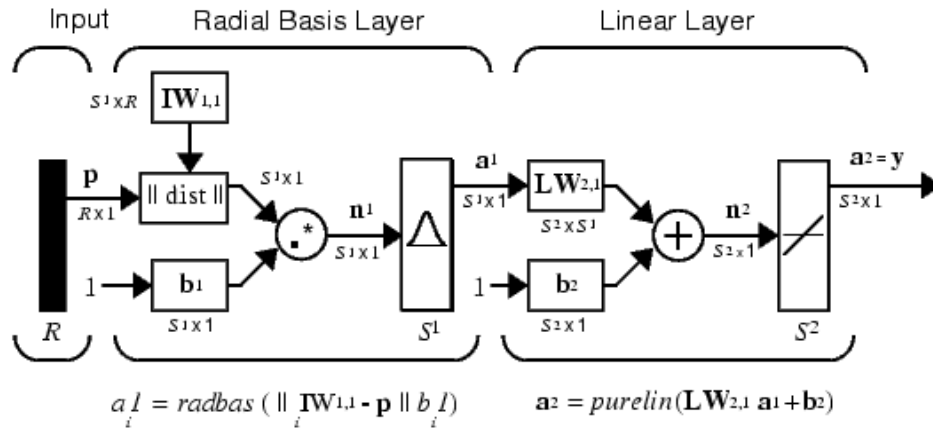


Ilustración 27: Topología de una red de base radial [19]

Como se aprecia en la imagen anterior una red neuronal en base radial está compuesta de una capa oculta con S_1 neuronas en base radial y una capa de salida lineal con S_2 neuronas.

Mapas Autoorganizados o Redes SOM (Self Organized Map)

Un modelo SOM está compuesto por dos capas de neuronas. La capa de entrada (formada por N neuronas, una por cada variable de entrada) se encarga de recibir y transmitir a la capa de salida la información procedente del exterior. La capa de salida (formada por M neuronas) es la encargada de procesar la información y formar el mapa de rasgos. Normalmente, las neuronas de la capa de salida se organizan en forma de mapa, tal y como representa la ilustración 28, aunque a veces también se utilizan capas de una sola dimensión (cadena lineal de neuronas) o de tres dimensiones (paralelepípedo) [20].




Ilustración 28: Topología de una red SOM

CAPÍTULO 3: Sistema experimental

3.1 Introducción

En el esquema de la ilustración 29 se muestra el proceso que se seguirá para obtener un sistema que permita clasificar las señales obtenidas en función del tipo de fallo que presente el rodamiento.



Ilustración 29: Esquema del proceso de clasificación de las señales

En este capítulo trataremos el primer paso, la obtención de la señal. Los puntos dos y tres se verán en detalle en el Capítulo 4, mientras que el punto 4, obtención de resultados se presenta en los Capítulos 5 y 6.

3.2 Sistema Experimental

3.2.1 Los rodamientos

Un rodamiento es un elemento mecánico que reduce la fricción entre un eje y las piezas conectadas a éste, que le sirve de apoyo y facilita su desplazamiento.

El rodamiento es un elemento normalizado que consta de dos aros concéntricos entre los que se desplazan unos cuerpos rodantes. Estos cuerpos rodantes suelen ir sujetos en la jaula. En la siguiente imagen (ilustración 30) se muestran los principales elementos que componen un rodamiento.




Ilustración 30: Partes que componen un rodamiento

Tipos de rodamientos

Podemos clasificar los rodamientos de diversas maneras como por ejemplo según el elemento rodante o su forma de trabajo [23]. De este modo nos podemos encontrar:

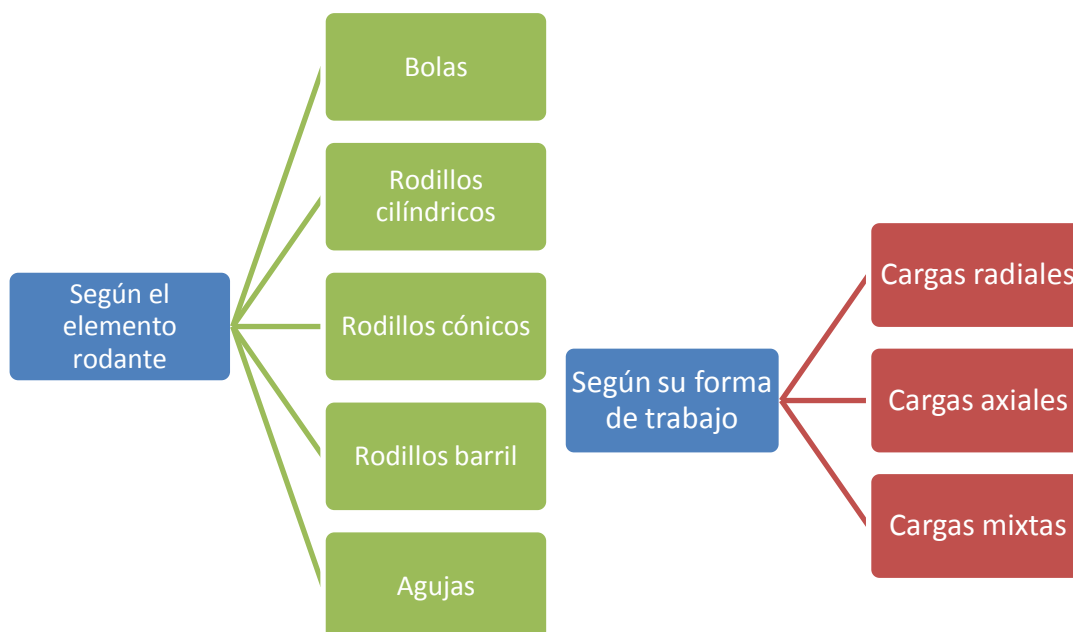


Ilustración 31: Esquema de clasificación de rodamientos

El conjunto de estas posibilidades así como utilizar una o más de una línea de elementos rodantes nos da una amplia gama de configuraciones [22], como se mostrará en las ilustraciones 32, 33 y 34:

- Rodamientos radiales




Ilustración 32: Tipos de rodamientos radiales

- Rodamientos axiales

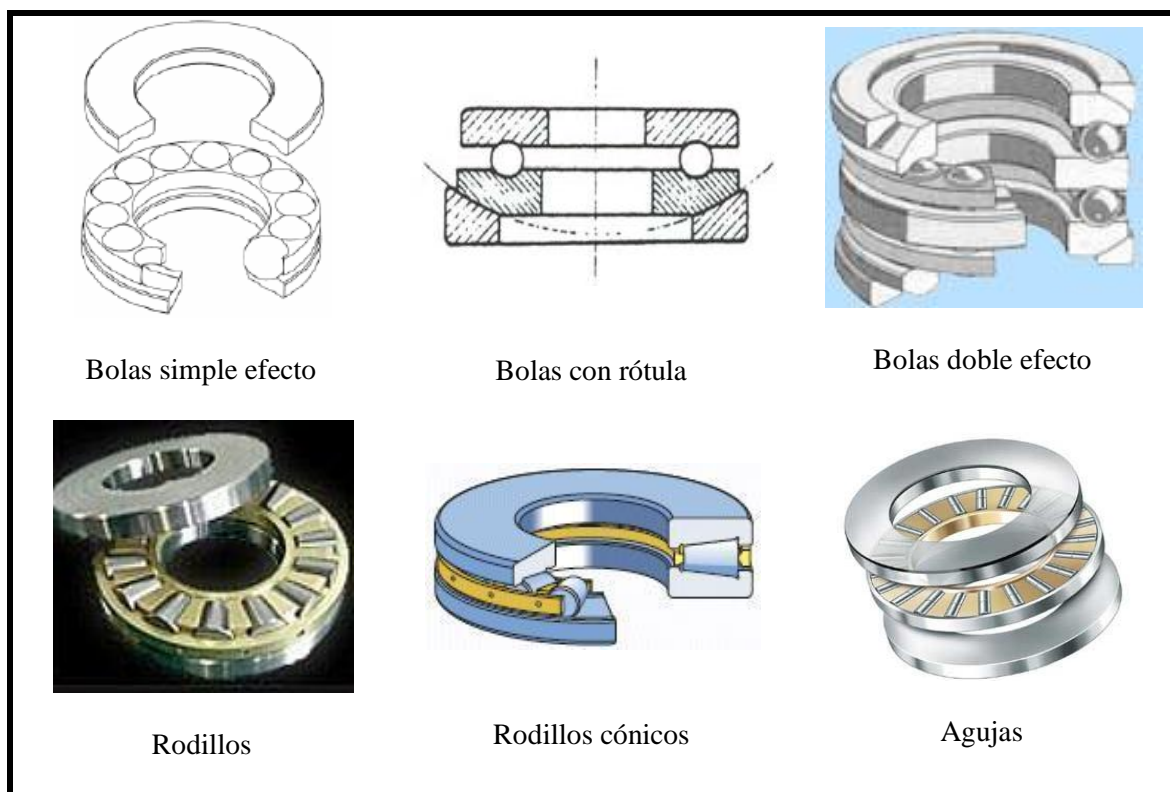


Ilustración 33: Tipos de rodamientos axiales

- Rodamientos mixtos




Ilustración 34: Tipos de rodamientos mixtos

Principales causas de fallos y defectos

La selección correcta del tipo de rodamiento es fundamental ya que de ello dependerá el funcionamiento del sistema. Para ello deberemos determinar las condiciones de carga, velocidad y tiempo de funcionamiento así como las variables ambientales que puedan afectar [24, 25].

Dado que existen multitud de situaciones de trabajo posibles aparecen numerosos tipos de defectos en los rodamientos de los que cabe destacar los mostrados en la ilustración 35.

Fatiga superficial	Descarga eléctrica
Se desarrolla en servicio un agrietamiento en las superficies con posterior pérdida de material, el cual puede ser poco profundo (micropicado) o generar descascarillado de áreas grandes y profundas (macropicado).	Por paso de corriente eléctrica AC o DC a través del rodamiento se generan arcos eléctricos entre los elementos rodantes, las pistas y las jaulas, que erosionan las superficies debido a fusión a pequeña escala.
  	 
Desgaste abrasivo	Desgaste adhesivo
Se presenta en servicio la generación de un rayado abrasivo sobre las superficies de rodadura y también sobre las jaulas, indicando que se está perdiendo material por abrasión.	Se presenta en servicio pérdida de material por contacto metal - metal entre las partes en rodamiento incluyendo las jaulas, producto de la pérdida parcial o total de la película lubricante.
 	 

Corrosión	Indentación
Se genera ataque corrosivo sobre las superficies de rodadura o las jaulas, por la acción del lubricante o de otro fluido que entra en contacto con el rodamiento, generándose daño superficial y depósitos.	Se trata de generación de cráteres o hendiduras sobre las superficies de rodadura, producto de la deformación plástica derivada de fuerzas de contacto excesivas entre los elementos del rodamiento y/o por presencia de partículas contaminantes entre ellos.
	
Fractura	Ludimiento
Las pistas o las jaulas presentan agrietamiento o fractura en montaje o servicio, llevando algunas veces a destrucción total del rodamiento.	Se presentan depósitos oscuros en las superficies de apoyo con el eje o su alojamiento, indicando que en servicio se dieron pequeños movimientos oscilantes entre las partes (desgaste y/o oxidación).
	

Ilustración 35: Tipos de defectos en rodamientos

Obviamente estos defectos se producen por causas determinadas, de las cuales cabe destacar como causas principales de defectos en rodamientos las mostradas en el gráfico de la ilustración 36 y el esquema de la ilustración 37.




Ilustración 36: Causa de defectos en rodamientos [25]

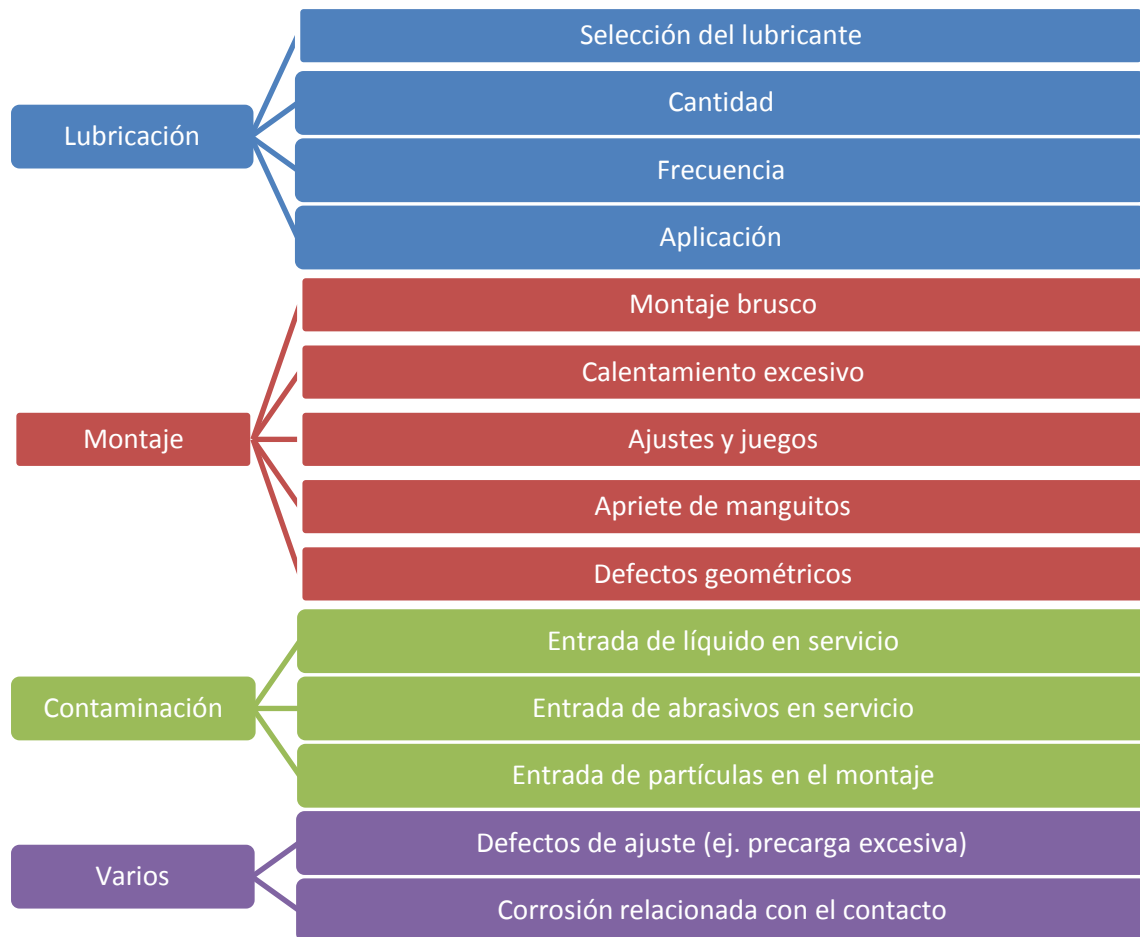


Ilustración 37: Principales causas de defectos en rodamientos

Rodamientos empleados

En nuestro caso emplearemos rodamientos de la marca *MB manufacturing* modelo ER10K como el que se muestra en la ilustración 38.



Ilustración 38: ER10K de MB manufacturing

Las principales características de este rodamiento se muestran en la tabla 1.

Diámetro interior [mm]	15,875
Diámetro exterior [mm]	46,99
Diámetro medio [mm]	33,49
Diámetro de bolas [mm]	7,94
Número de bolas	8
Ángulo de contacto [°]	0

Tabla 1: Principales características del ER10K

Para la realización del presente Proyecto se emplearán cuatro condiciones diferentes de este modelo de rodamiento, todos ellos proporcionados por la empresa *Spectra Quest* como accesorio de la *Machine Fault Simulator Lite*: rodamiento sano, rodamiento con defecto en pista interna (Inner), rodamiento con defecto en pista externa (Outer) y rodamiento con defecto en bola (Ball).

En el momento de la realización del PFC no se disponía de información detallada de los defectos, ya que la empresa suministradora no los facilita, y el desmontaje del rodamiento quedó descartado ya que afectaría a sus propiedades en servicio, pudiendo agravarse los defectos.

Una característica importante de estos elementos que nos puede ser útil en la determinación de defectos son las frecuencias de sus diferentes partes, de modo que la frecuencia natural de flexión de las pistas (Ec. 3.1.1) y la frecuencia natural de flexión de las bolas (Ec. 3.1.2) quedan:

$$w_{nb} = \frac{0.848}{d} \cdot \sqrt{\frac{E}{2 \cdot \rho}}$$

(Ec. 3.1.1)

$$w_{nr} = \frac{i \cdot (i^2 - 1)}{a^2 \cdot \sqrt{1 + i^2}} \cdot \sqrt{\frac{E \cdot I}{m}}$$

(Ec. 3.1.2)

Donde:

w_{nb} : Frecuencia natural de flexión de las pistas, del modo $n = i$.

w_{nr} : Frecuencia natural de flexión de las bolas.

d : Diámetro de las bolas

E : Modulo de elasticidad del metal

ρ : Densidad del metal

i : Número de ondulaciones alrededor de la circunferencia ($=2,3,4,\dots$)

a : Radio del eje neutro

I : Momento de inercia de la sección transversal

m : Masa de la pista por unidad de longitud

En la ilustración 39 se pueden observar las secciones frontal y transversales de un rodamiento de bolas.




Ilustración 39: Sección frontal y transversal de un rodamiento

Donde:

v_i : velocidad de la pista interna

v_c : velocidad de la bola

v_o : velocidad de la pista exterior

B_d : diámetro de la bola o rodillo

P_d : diámetro efectivo del rodamiento

Φ : ángulo de contacto tomado desde la línea central de la bolita y el eje del rodamiento.

Para la suposición ideal de pista exterior estacionaria y pista interna rodando, situación similar a la que nos encontramos en nuestro caso podemos aproximar las frecuencias típicas de un rodamiento con un error estimado de $\pm 20\%$.

$$BCF = \frac{RPM}{60} \cdot \left(\frac{1}{2}\right) \cdot \left(1 - \frac{B_d \cdot \cos \phi}{P_d}\right) \approx 0.4 \cdot \frac{RPM}{60} \quad (\text{Ec. 3.1.3})$$

$$BPFO = \frac{RPM}{60} \cdot \left(\frac{N_b}{2}\right) \cdot \left(1 - \frac{B_d \cdot \cos \phi}{P_d}\right) \approx 3.2 \cdot \frac{RPM}{60} \quad (\text{Ec. 3.1.4})$$

$$BPFI = \frac{RPM}{60} \cdot \left(\frac{N_b}{2}\right) \cdot \left(1 + \frac{B_d \cdot \cos \phi}{P_d}\right) \approx 4.8 \cdot \frac{RPM}{60} \quad (\text{Ec. 3.1.5})$$

$$BSF = \frac{RPM}{60} \cdot \left(\frac{P_d}{2 \cdot B_d}\right) \cdot \left(1 - \frac{B_d^2 \cdot \cos^2 \phi}{P_d^2}\right) \approx 1.84 \cdot \frac{RPM}{60} \quad (\text{Ec. 3.1.6})$$

Donde:

BCF : Frecuencia fundamental del tren de elementos

$BPFO$: Frecuencia de paso de las bolas por la pista exterior

$BPFI$: Frecuencia de paso de las bolas por la pista interior

BSF : Frecuencia de giro de las bolas sobre su eje

N_b : Número de bolas

Estas frecuencias son importantes ya que nos indicarían la presencia de un tipo de defecto en caso de análisis estacionario simplemente analizando el espectro de frecuencias. Sin embargo en caso de un análisis transitorio estas frecuencias varían linealmente con la velocidad, y en principio no nos serán de gran utilidad a la hora de clasificar las señales.

3.2 El sistema de ensayos

Para la adquisición de las señales vibratorias necesitamos un sistema en el que realizar los ensayos. Este pertenece al departamento de Ingeniería Mecánica de la Universidad Carlos III de Madrid y está formado por los siguientes elementos.

1. *Machine fault simulator lite*

La *MFS-LITE* es un banco de ensayos diseñado por la empresa *Spectra Quest* para estudiar distintos fallos que se producen en máquinas rotativas como puede ser fisuras en ejes, desalineamientos, desequilibrios o fallos en rodamientos.

El equipo está fabricado en base de aluminio y su peso y dimensiones son de 45 kg y 80x36x55 cm. En la ilustración 40 se pueden apreciar los elementos que componen la *MFS-Lite*:



Ilustración 40: Machine Fault Simulator Lite

El equipo consta de:

- Motor eléctrico trifásico Marathon “Four in One” Modelo DV3
- Variador de frecuencia: Nos permite modificar la velocidad de giro del motor y gracias a su menú podemos configurar con precisión los rangos y la duración de la aceleración.
- Tacómetro: Junto con un elemento reflectante dispuesto en el eje del rotor nos permite registrar la velocidad de giro del motor.
- Juego de rodamientos con distintos tipos de fallos: De la marca SKF incorporan diferentes tipos de fallo y su combinación, así como un juego de rodamientos “sanos” para su comparación con el resto de fallos.
- Juego de cargas de distintos pesos y dimensiones. Tenemos cargas de 1 kg y 5 kg
- Juego de acoples flexibles o rígidos de distintos tipos
- Par de carcasas para acople de rodamientos

En la ilustración 41 se puede ver la ubicación y disposición de los elementos mencionados con anterioridad en la *MFS-Lite*.




Ilustración 41: Elementos que componen la Machine Fault Simulator Lite

2. Acelerómetro

El acelerómetro se emplea para medir la aceleración en las vibraciones de un elemento. Consiste en una lámina de material piezoeléctrico, que al estar sometido a compresión mecánica o tensiones de corte, genera cargas eléctricas en las caras, proporcionales a la fuerza aplicada. Puede experimentar tres tipos de deformación mecánica las cuales son: compresión, flexión, y cizallamiento o deformación de corte.

Para nuestro caso utilizaremos un acelerómetro triaxial de la marca MMF modelo KS-943B.10 como el que se muestra en la ilustración 41. La imagen muestra la dirección de la vibración en X e Y, siendo fundamental de cara a la obtención de la señal.





Ilustración 42: Acelerómetro triaxial MMF KS 943B.10 y medidas

Su respuesta en frecuencia típica nos muestra un ancho de banda entre 2 y 9.000 Hercios, siendo por ello apto para nuestro ensayo. Su respuesta en frecuencia y sus características se muestran en la ilustración 43 y la tabla 2 respectivamente.




Ilustración 43: Respuesta en frecuencia del acelerómetro triaxial MMF KS 943B.10

Otras características de relevancia del acelerómetro:

Características			
Sensibilidad	B_{UA}	$10 \pm 5\%$	mV/g
Rango de carga	a_{+}/a_{-}	600	g
Límite de carga	a_{max}	8000	g
Rango de frecuencia lineal (eje z)	f_{3dB}	0,2..22000	Hz
	$f_{10\%}$	0,4..17000	Hz
	$f_{5\%}$	0,6..15000	Hz
Frecuencia de resonancia	f_r	> 42 (25 dB)	kHz
Ruido residual (RMS, 3 Hz – 50 kHz)	$a_n \text{ wide band}$	< 3000	μg
Rango operativo de temperatura	T_{min}/T_{max}	-20 / 120	°C
Peso		14	g
Material de la carcasa		Aluminio	

Tabla 2: Características del acelerómetro triaxial MMF KS 943B.10

3. Filtros

El propósito de un filtro es eliminar señales. Un filtro para ruido se usa en señales continuas, ya que atenúan señales de alta frecuencia debido a que estas pueden reducir la precisión de las mediciones.

Las señales discretas, como las de vibraciones a menudo requieren un tipo diferente de filtros conocidos como filtros antialiasing. Al igual que un filtro de ruido, el filtro antialiasing es también un filtro paso bajo; sin embargo, debe tener una tasa de truncado muy abrupta, es decir que elimine completamente todas las frecuencias de la señal que son más altas que la entrada de ancho de banda de la tarjeta.

La ilustración 44 represente el filtro antialiasing empleado en este caso.



Ilustración 44: Filtro utilizado

4. Tarjeta de adquisición de datos

La tarjeta de adquisición de datos es de la marca Keithley modelo KUSB 300 como la mostrada en la ilustración 45. Su función es la de convertir la señal analógica adquirida por los sensores en una señal digital para su posterior procesamiento en un ordenador.




Ilustración 45: Tarjeta de adquisición de datos

5. Software

Para la obtención de las señales conectaremos la tarjeta de adquisición a un ordenador portátil que dispone del software TestPoint v7 instalado.

TestPoint es una herramienta para crear aplicaciones capaces de realizar mediciones, pruebas y adquirir datos que incluye características para controlar el hardware externo, creando interfaces de usuario, procesando y mostrando datos, creando archivos de informe, y cambiando la información con otros programas, como en nuestro caso, Matlab [26].

6. Ordenador

Para el procesamiento y clasificación de los datos es necesario un equipo potente, ya que estos procesos requieren gran capacidad de cálculo y memoria. Por este motivo así como por su constante necesidad de uso empleé mi ordenador principal cuyas características muestro a continuación.

Ordenador	
Tipo de ordenador	Equipo basado en ACPI x86
Sistema operativo	Microsoft Windows Vista Ultimate
Service Pack del Sistema Oper...	-
Internet Explorer	8.0.7600.16385
DirectX	DirectX 10.0
Nombre del sistema	USER-PC
Nombre de usuario	User
Nombre de dominio	User-PC
Fecha / Hora	2010-09-21 / 09:53
Placa base	
Tipo de procesador	QuadCore Intel Core 2 Quad Q6600, 2400 MHz (9 x 267)
Nombre de la Placa Base	Desconocido
Chipset de la Placa Base	Desconocido
Memoria del Sistema	3072 MB
Tipo de BIOS	AMI (10/30/07)
Puerto de comunicación	Puerto de comunicaciones (COM1)
Monitor	
Tarjeta gráfica	NVIDIA GeForce 8600 GTS

Al tener un procesador de cuatro núcleos los cálculos no se verán afectados por procesos ajenos, y sus tres Gigabytes de memoria RAM permiten realizar cálculos con nuestras señales de gran tamaño.

A pesar de sus características Matlab requiere en algunas ocasiones más cantidad de memoria que la que disponemos, por lo que algunos cálculos no podrán ser realizados.

3.3 Metodología del ensayo

Descripción del ensayo

El objetivo es obtener numerosas muestras de las señales vibratorias que produce un rodamiento durante una rampa de aceleración estándar configurada previamente. Para obtener las muestras deseadas emplearemos el material mencionado en el apartado anterior.

En la ilustración 46 se representa la cadena de medida para la obtención de datos.




Ilustración 46: Cadena de medida

Primero se monta y configura el banco de ensayos (Punto1), a continuación se sitúa y cablea el acelerómetro triaxial en el soporte del rodamiento más próximo al motor (Punto 2). El siguiente paso es conectar un filtro a cada señal procedente del acelerómetro (Punto 3). Estos filtros se conectan cada uno a una entrada de la tarjeta de adquisición de datos y a masa (Punto 4). Por último la tarjeta se conecta por USB a un ordenador con TestPoint instalado (Punto 5).

Para obtener la muestra pulsaremos simultáneamente el botón de encendido del variador de frecuencia y el botón de adquirir señal del programa realizado en TestPoint.

Configuración del sistema de ensayos

El banco de ensayos nos da la posibilidad de actuar sobre algunos de sus elementos con el fin de obtener los mejores ajustes para nuestro experimento en concreto. En nuestro caso podremos realizar actuaciones sobre el material del eje, la disposición de los pesos y la rigidez del acoplamiento.

El eje puede ser de aluminio o de acero y puesto que en principio entre uno y otro los resultados finales no ofrecen gran diferencia optamos por utilizar un eje de acero, ya que por una parte nos ofrece mayor seguridad y por otra parte el eje de aluminio está orientado al análisis de defectología en ejes fisurados.

En cuanto a la disposición de los pesos cargaremos el eje lo máximo posible en su zona central para aumentar al máximo el momento flector sobre el rodamiento a analizar y con ello obtener señales vibratorias de mayor precisión. Emplearemos dos discos de 5 kg cada uno.

Por último escogeremos un acoplamiento de goma, ya que su menor rigidez aísla el eje del eje-motor e impide que aparezcan en nuestro ensayo vibraciones cuyo origen sea el motor trifásico.

Tamaño y duración de la muestra

Es necesario determinar el tamaño y la duración de la muestra tanto en la M.F.S. como en el TestPoint. Para ello primero determinamos la velocidad máxima de la rampa de aceleración y el tiempo de aceleración. Por experiencias previas mi tutor y yo establecemos una velocidad máxima de 80 Hz (4.800 rpm) y una duración de la rampa de 10 segundos que se configuran en el variador de frecuencias.

Una vez determinadas las características de la rampa de aceleración debemos establecer una toma de datos que se ajuste a la rampa y con la que se pierda la menor información posible sin excedernos en el tamaño de la señal, ya que ralentizaría el posterior procesado. Decidimos establecer una muestra de 12 segundos (dos segundos mayor que la rampa de aceleración para no perder información) con una frecuencia de muestreo de 5.000 Hz, lo que nos dará muestras de un tamaño de 60.000 puntos. Esta decisión se tomó basada en la experiencia personal de mi tutor en casos similares.

El resultado final serían señales de 60.000 datos y un tamaño aproximado de 2.3 Megabytes, lo que permite un procesado en tiempos que consideramos razonables y nos dan una gran cantidad de información.

CAPÍTULO 4: Sistema de detección y diagnosís

4.1 Procesamiento de las señales obtenidas

4.1.1 El entorno MATLAB

MATLAB (*MATrix LABoratory*) es un software matemático muy utilizado en el ámbito universitario que ofrece un entorno de desarrollo integrado con un lenguaje de programación propio (lenguaje M). En la ilustración 47 se detalla la versión empleada.

Entre sus prestaciones básicas se hallan: la manipulación de matrices, la representación de datos y funciones, la implementación de algoritmos, la creación de interfaces de usuario y la comunicación con programas en otros lenguajes y con otros dispositivos hardware. El paquete MATLAB dispone de herramientas adicionales que expanden sus prestaciones: Simulink (plataforma de simulación multidominio) y GUIDE (editor de interfaces de usuario - GUI). Además, se pueden ampliar las capacidades de MATLAB con las cajas de herramientas (*toolboxes*).




Ilustración 47: MATLAB

Para el desarrollo del presente proyecto usaremos la versión R2008a, ya que incluye una toolbox fundamental para el procesamiento de señales, el *Wavemenu*, mostrado en la ilustración 48.

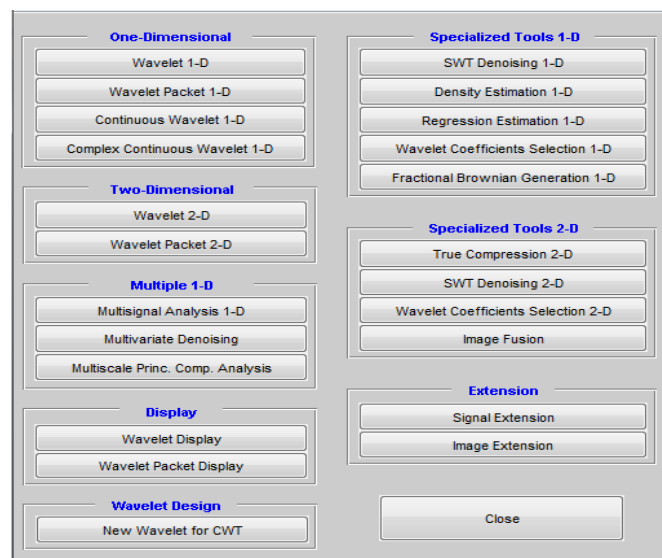


Ilustración 48: Wavemenu

Lo importante de esta herramienta no radica en el programa en sí, que únicamente emplearemos como apoyo, sino en las funciones matemáticas que incluye y que nos facilitarán la programación en gran medida.

4.1.2 Señales obtenidas del ensayo

Del ensayo en laboratorio se obtiene un archivo de datos *.dat que contiene tres columnas y sesenta mil filas. La primera columna corresponde con la velocidad angular, la segunda se refiere a la amplitud de la vibración en el eje X y la tercera a la amplitud de la vibración en el eje Y. El sistema de referencia se muestra en la ilustración 41.

Las señales obtenidas tienen la apariencia mostrada en la ilustración 49, cuyo eje de ordenadas representa los puntos (es decir el tiempo) y el eje de abscisas la amplitud de la señal.




Ilustración 49: Señales obtenida de Testpoint. Arriba señal Y. Abajo señal X

4.1.3 Métodos de procesamiento de la señal empleados

Todos los métodos empleados tienen una base de preprocesamiento que se desarrolla a continuación hasta obtener la que denominaremos señal íntegra. Todo el procesamiento se desarrolla en el entorno de MATLAB y sus diferentes aplicaciones.

- Tratamiento previo de la señal

El preprocesamiento se realiza principalmente gracias a la herramienta Import Wizard. Con esta herramienta transformamos el archivo *.dat en una variable de MATLAB capaz de ser empleada por el programa. Una vez tenemos la variable de cada señal la dividiremos en las tres partes que la compone, es decir, una para la velocidad angular, una para la señal en X y otra para la señal en Y, tal y como representa la ilustración 50.

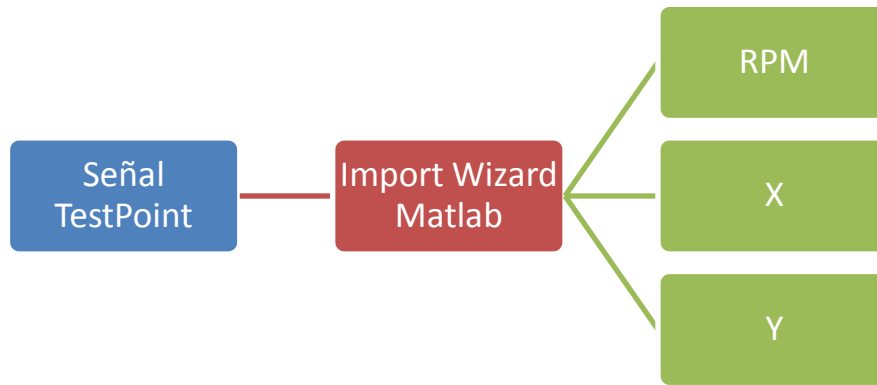


Ilustración 50: Esquema de tratamiento previo de la señal

Una vez tratada la señal usaremos cuatro métodos diferentes en busca de resultados a la hora de su posterior clasificación: la señal íntegra, la reconstrucción del paquete Wavelet (RCFS), los coeficientes del paquete Wavelet (CFS) y por último la energía del paquete Wavelet.

Los tres últimos están basados en la teoría de la transformada Wavelet y su energía. Además poseen una parte de procesado común que denominaremos Preprocesamiento Wavelet. Éste será desarrollado utilizando funciones propias de la *toolbox* de wavelets implementadas en el entorno de edición de Matlab. La ilustración 51 muestra los diferentes procesamientos que realizamos partiendo de la señal vibratoria en el eje Y cuya dirección quedó representada en la Ilustración 41.

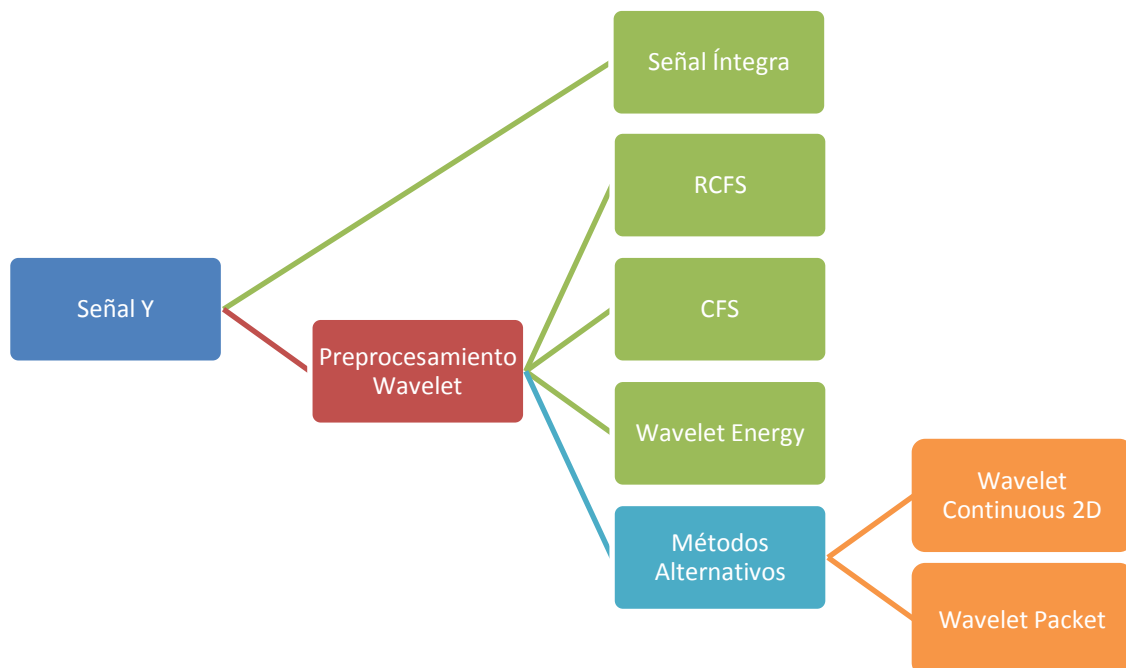


Ilustración 51: Esquema de procesamiento

- Métodos alternativos

Como complemento al Preprocesamiento Wavelet se utilizará la aplicación *Wavelet Packet* incluida en el *Wavemenu* así como la Transformada Wavelet Continua. El objetivo de estos métodos no es obtener señales para su clasificación, sino ayudarnos a verificar los datos resultantes del Procesamiento Wavelet.

El Wavelet Packet nos permite hacernos con la idea principal de lo que es una wavelet y lo que podemos obtener de ella y a qué nivel. También nos permite comprobar los resultados que se obtienen del Preprocesamiento Wavelet.

Esta herramienta, mostrada en la ilustración 52 presenta en la esquina superior izquierda el árbol de descomposición (*Decomposition tree*). En él podemos comprobar la energía y la posición (aparte de otras características) de cada paquete. Bajo él se muestra la señal reconstruida de un paquete concreto (*Reconstructed Packet*), que como se observa, difiere de la señal original mostrada a la derecha del árbol (*Analyzed signal*). Por último en la cuadrícula inferior derecha se muestran los coeficientes de los paquetes del último nivel en el rango de frecuencias (*Colored coefficients for terminal nodes*). En el menú de la derecha se pueden elegir los tipos de análisis así como las opciones de visualización.

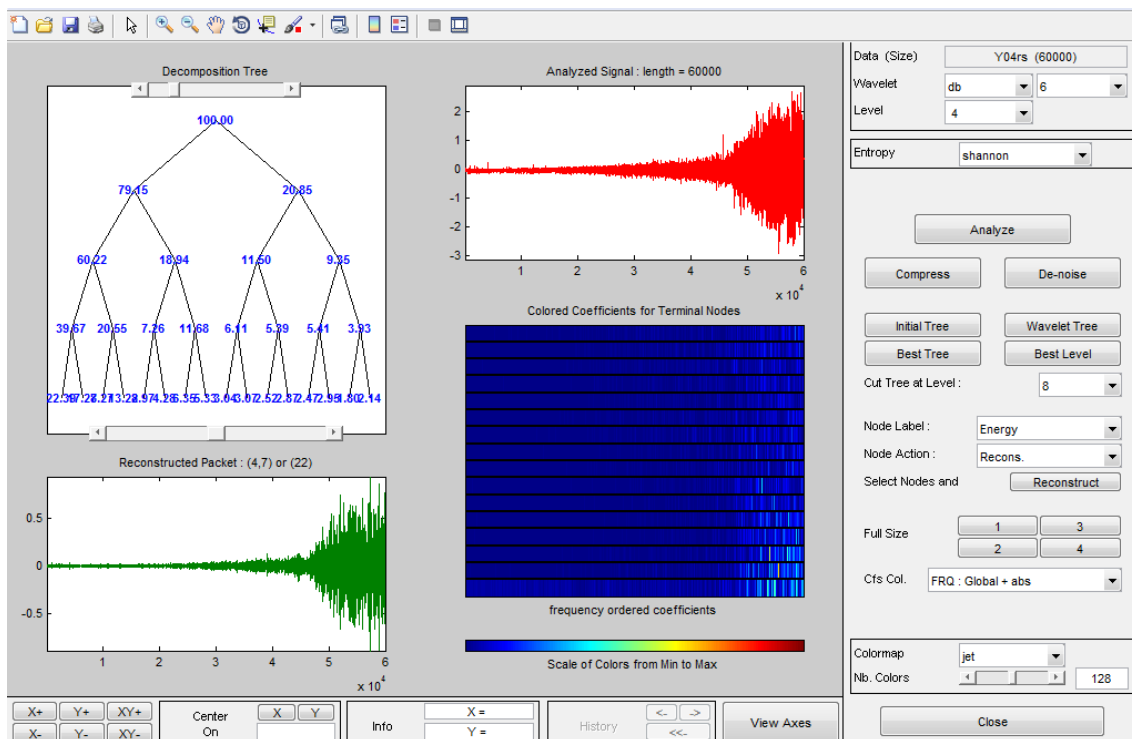


Ilustración 52: Wavelet Packet

La TWC (*Continuous Wavelet ID* según la nomenclatura del *wavemenu*) es la visualización de la Transformada Wavelet a partir de los ejes de los coeficientes y su distribución temporal (ilustración 53). Nos permite hacernos a la idea de en qué zonas temporales y a qué frecuencias aparecen los puntos críticos. La frecuencia es exponencial, como se explica en el Capítulo 2: Estado del Arte, por lo que la zona de altas frecuencias es mucho menor que la zona de bajas. Dependiendo de la cantidad de coeficientes la figura mostrará con más detalle la zona de bajas frecuencias.

A continuación, en la ilustración 53, se presenta un ejemplo de cómo sería la Transformada Wavelet Continua de una señal de rodamiento con defecto en pista externa:




Ilustración 53: Transformada Wavelet Continua

- Señal íntegra

Este método consiste básicamente en introducir la señal preprocesada directamente en el sistema clasificador, ya que si este es capaz de diferenciar las señales íntegras con un buen acierto sería el método más rápido de clasificación y nos ahorraría la parte de procesamiento Wavelet, que es la parte más lenta y duradera del análisis.

En principio únicamente emplearemos la señal “Y” ya que es la que registra las vibraciones con mayor amplitud, y sólo en caso de ser necesario utilizaremos “X”. La matriz de inputs del sistema clasificador será una matriz de $m \times n$ donde “m” es el tamaño de la señal y “n” el número de señales. La ilustración 54 representa la señal íntegra analizada.




Ilustración 54: Señal íntegra

- Preprocesamiento Wavelet

Esta es posiblemente la parte más importante del procesamiento de la señal ya que de ella obtendremos tres métodos distintos para la posterior clasificación.

Está programada en su totalidad en MATLAB y se basa en la energía contenida por un paquete Wavelet. Emplearemos como señal wavelet madre Daubechies de orden seis (db6) y distintos niveles de descomposición entre cinco y ocho. El motivo de esta elección es que para procesamiento wavelet de señales de cara a clasificación mediante una red neuronal Daubechies cumple con los requisitos necesarios, y dada que es la más simple después de la Haar acorta notablemente la duración del procesamiento. Además es recomendada y utilizada en numerosos estudios similares.

En el siguiente esquema de procesos se explican los pasos que sigue el programa hasta obtener los resultados deseados.



1. El programa carga las señales y las organiza en dos matrices: una matriz en la que cada columna es una señal sana y otra matriz en la que cada columna es una señal con defecto.
2. Se determina la energía de cada paquete Wavelet de cada señal y obtenemos la diferencia de energía entre el paquete del rodamiento sano y el de rodamiento con defecto, ordenándolos de mayor a menor. Obtenemos una matriz en la que cada columna son los 20 niveles energéticos de una señal con defecto con mayor diferencia de energía con la señal de rodamientos sanos.
3. Se buscan y ponderan los niveles más repetidos para cada tipo de defecto. Obtenemos una pequeña matriz en la que se muestran los cinco niveles más repetidos para cada tipo de defecto como la presentada en la tabla 3.

	Defecto en pista interna	Defecto en pista externa	Defecto en bola
Primer nivel	145	136	136
Segundo nivel	183	145	183
Tercer nivel	134	187	145
Cuarto nivel	175	154	154
Quinto nivel	187	158	175

Tabla 3: Ejemplo de tabla de mejores paquetes de nivel 8 (db6)

- Para obtener RCFS y CFS seleccionamos un nivel que se repita en los tres defectos. Para la energía del paquete wavelet creamos una matriz en la que cada columna es una señal (tanto de sano como de defecto) y cada fila es la energía del paquete wavelet, analizando los cinco niveles más repetidos de un tipo de defecto.

Como ayuda en esta parte y para comprobar que utilizamos los niveles correctos generaremos una gráfica que represente el espectro de energías de cada nivel wavelet para cada tipo de señal, como la representada en la ilustración 55.




Ilustración 55: Energía de cada paquete del octavo nivel de todas las señales (db6)

En la figura se aprecian varias zonas en las que los cuatro tipos de señales se diferencian notablemente y en las que será mejor su diferenciación.

Esta figura es posiblemente más importante que todo el preprocesamiento ya que nos permite evitar el solapamiento. Este se produce si el nivel que nos da el preprocesamiento es tal que los tres tipos de defecto tengan similar energía y se enmascaren entre sí.

- RCFS, CFS y Energía del paquete Wavelet

Una vez obtenemos esta tabla al programa se le indicará el nivel deseado para obtener la señal reconstruida (RCFS) y sus coeficientes (CFS) y los agrupará en una tabla. Además obtendrá la energía de los cinco niveles de la señal de defecto en pista interna para todas las señales y las agrupará en otra tabla.

En resumen, introducimos en el procesamiento los datos obtenidos en el ensayo y obtenemos los análisis mostrados en la ilustración 56.

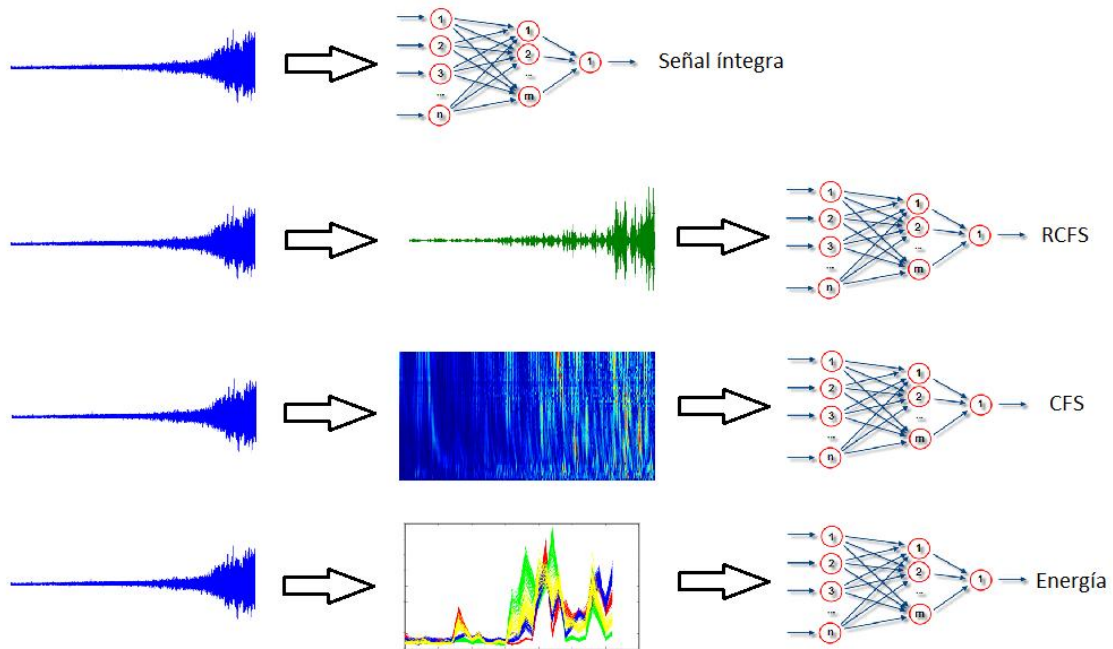


Ilustración 56: Tipos de análisis realizados dependiendo del procesamiento de señales empleado

4.2 SISTEMA CLASIFICADOR

4.2.1 MATLAB

Al igual que en el procesamiento de la señal, MATLAB dispone de una herramienta fundamental para el desarrollo del Proyecto, la *toolbox* de redes neuronales (*Neural Network Toolbox*).

A diferencia del *Wavemenu*, este programa será ampliamente utilizado y llamado como subrutina por los programas que generemos ya que permite realizar el entrenamiento de numerosos tipos de red neuronal, además de permitirnos variar los parámetros del entrenamiento como el aprendizaje, el error, el tipo de entrenamiento...

En la ilustración 57 se observa el *Neural Network Training Display*, que es la herramienta empleada para realizar el entrenamiento en MATLAB y que viene incluida desde la versión de 2008. Antes este proceso se programaba manualmente para cada tipo de red, lo que implicaba altos tiempos de programación.

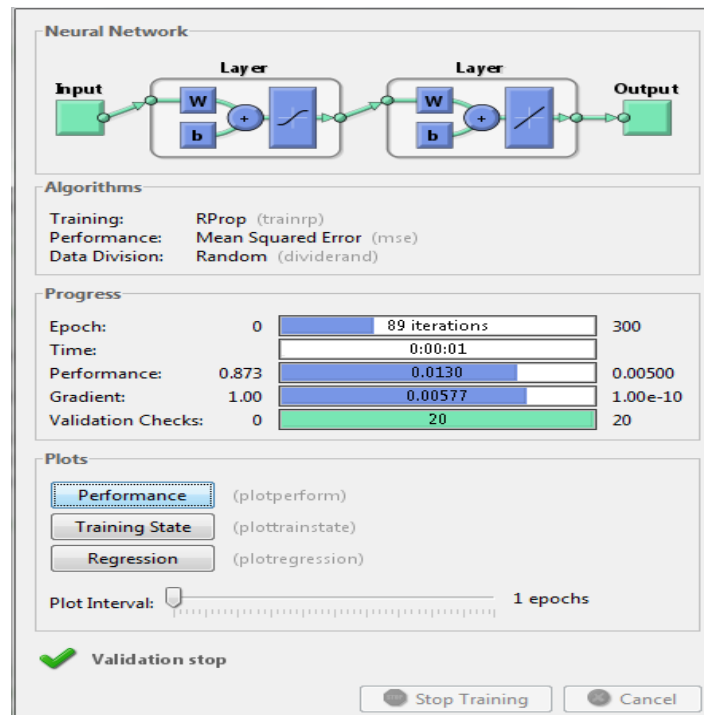


Ilustración 57: *Neural Network Training Display*

En ella podemos variar múltiples parámetros como el tipo de entrenamiento, el tipo de error y su valor objetivo, el número de iteraciones, el número de validaciones o el gradiente del error.

4.2.2 FUNCIONES Y PARÁMETROS DE MATLAB

A la hora de proceder a entrenar la red neuronal, MATLAB nos permite variar una serie de parámetros para ajustar el entrenamiento y obtener mejores resultados. Para ello se debe conocer el funcionamiento de cada variable, el carácter de las entradas (inputs) y los objetivos (targets), y la forma de los resultados de salida.

De este modo podremos actuar sobre las siguientes variables:

- Función de transferencia: nos encontraremos con cuatro tipos de funciones de transferencia:
 - “Purelin” o función de transferencia lineal.
 - “Tansig” o función de transferencia tangente hiperbólica sigmoidea.
 - “Logsig” o función de transferencia logarítmica sigmoidea.
- Función de cálculo del error: dependiendo del tipo de red neuronal emplearemos diferentes métodos de cálculo de error, como:
 - “mae” (*Mean average error performance function*): Poco empleado pero muy simple. No nos proporcionará buenos resultados.
 - “mse” (*Mean squared error performance function*): Método de mínimos cuadrados. Simple en cálculos y nos da buenos resultados.
 - “msen” (*Mean squared normalized error performance function*): similar al anterior pero normalizando los resultados. No nos proporciona una mejoría apreciable respecto al anterior.
- Funciones de aprendizaje: las más empleadas son:
 - “Learngd” (*Gradient descent weight and bias learning function*): es la función de aprendizaje más empleada y por defecto se empleará en redes del tipo perceptrón multicapa.
 - “Learnqdm” (*Gradient descent with momentum weight and bias learning function*): muy similar a la anterior, pero consume más recursos, por lo que apenas será empleada.
 - “Learnqom”: empleada para redes SOM.
- Funciones de entrenamiento: existen numerosas opciones que se diferencian principalmente en el tiempo que emplean y los recursos que consumen:
 - “Trainlm” (*Levenberg-Marquardt backpropagation*): Empleado en redes perceptrón multicapa, es el más rápido, pero consume una altísima cantidad de memoria.
 - “Trainbfg” (*BFGS quasi-Newton backpropagation*): Empleado como el anterior, es un poco más lento y consume menos memoria.
 - “Trainrp” (*Resilient backpropagation*): También para redes perceptrón multicapa esta función de entrenamiento será la que más empleemos ya que a pesar de ser la más lenta de las tres nos permitirá completar un mayor número de análisis.
 - “Trainbuwb” (*Batch unsupervised weight/bias training*): método de entrenamiento no supervisado empleado en redes SOM.

- Otros parámetros: las siguientes estructuras de datos ajustan el entrenamiento:
 - “net.trainParam.epochs”: con este parámetro actuaremos sobre el número de iteraciones que se realizarán en el entrenamiento. El entrenamiento finalizará una vez alcanzadas las iteraciones indicadas. No interesa que el entrenamiento finalice debido a que el número de iteraciones haya sido insuficiente, por lo que estará estipulado en trescientas iteraciones.
 - “net.trainParam.show”: nos mostrará los progresos del entrenamiento cada “x” iteraciones.
 - “net.trainParam.goal”: con este parámetro indicamos el error objetivo que deseamos alcanzar. El programa finalizará el entrenamiento si se alcanza ese error. Por defecto lo estipulamos para todas las redes en 1×10^{-5} , aunque esto no implica que se alcanzará este valor.
 - “net.trainParam.max_fail”: actuando sobre este parámetro ajustamos el número de validaciones consecutivas que tienen que darse para que el entrenamiento finalice.

En principio nos interesa que el entrenamiento finalice porque se ha alcanzado el error objetivo, ya que sería el mejor indicativo de que la red ha sido bien entrenada. En caso de finalizar por producirse veinte fallos consecutivos lo más probable es que haya que repetir el entrenamiento o que no sea posible entrenar mejor la red, ya que no permite que el error descienda a niveles adecuados.

También puede darse el caso de que el entrenamiento finalice por que el gradiente del error producido disminuya mucho, de forma que se vuelva prácticamente estacionario. En este caso nos indica que la red ha llegado al límite de su capacidad.

4.2.3 TOPOLOGÍAS DE RED

Para el desarrollo del presente Proyecto emplearemos cuatro topologías de red con las que trataremos de analizar cómo funciona cada una de ellas en la clasificación de una señal transitoria y determinar así un procedimiento de clasificación de defectos de rodamientos. Las tablas 4, 5, 6 y 7 muestran sus principales características.

Red de base radial

Emplearemos una red radial simple fijando el error objetivo en diferentes valores y como límite 1×10^{-5} . También actuaremos sobre el ancho de campana o “spread”, ya que puede influir en los resultados. Para trabajar con coeficientes wavelet emplearemos spread = 1 y para energías emplearemos spread = 0.88. Estos datos se han obtenido tras realizar sendos bucles en los que para las mismas inputs variábamos centesimalmente el valor de spread entre 0.1 y 6, logrando los mejores resultados de clasificación para estos valores de ancho de la campana.

Para que la red radial pueda considerarse adecuada debemos prestar mucha atención al proceso de entrenamiento, en el que el error deberá disminuir gradualmente. Un problema muy común de estas redes, que se ha apreciado durante el desarrollo del presente Proyecto es que cuando la red, que va aumentando su número de neuronas en cada iteración y disminuyendo el error progresivamente, alcanza valores próximos a el número de inputs, es decir, en nuestro caso 240 neuronas, el valor del error cae súbitamente, falseando el entrenamiento y generando errores de clasificación.

Red de base radial			
Parámetros	Selección		
<i>Función de activación</i>	Capa oculta		Capa de salida
	Gaussiana		Lineal
<i>Número de Capas (3)</i>	• 1 entrada, 1 oculta y 1 salida		
<i>Número de neuronas</i>	Capa de entrada	Capa oculta	Capa de salida
	2 ⁿ (Donde n es el nivel de descomposición).	Variable	2

Tabla 4: Red de base radial

Red perceptrón multicapa feedforward

Este será el primer tipo de red perceptrón multicapa se empleará. La función de transferencia que emplearemos será tangente hiperbólica sigmoidea para las capas ocultas y función de transferencia lineal en la capa de salida. La función de aprendizaje será “Learnngm” y para la función de entrenamiento se utilizará “Trainrp” ya que los otros dos limitan el número de neuronas al requerir demasiada memoria operativa. Además para determinar el error se empleará mínimos cuadrados normales (*mse*).

Todas estas configuraciones son las más recomendadas para este tipo de red, sin embargo admite pequeñas variantes que tras probarlas no supusieron un cambio notable en los resultados obtenidos. Se probaron funciones de transferencia logarítmica sigmoidea, mínimos cuadrados normalizados así como la función de aprendizaje con momento en varias combinaciones.

Red Perceptrón Multicapa Feedforward			
Parámetros	Selección		
Función de activación	Capa oculta		Capa de salida
	Tangente Hiperbólica Sigmoidea		Lineal
Número de Capas (3)	• 1 entrada, 1 oculta y 1 salida		
Número de neuronas	Capa de entrada	Capa oculta	Capa de salida
	2 ⁿ (Donde n es el nivel de descomposición WP).	Variable	2

Tabla 5: Red Perceptrón Multicapa Feedforward

Red perceptrón multicapa de reconocimiento de patrones

Esta red es idéntica a la feedforward normal con la excepción de que la capa oculta tiene una función de transferencia logarítmico sigmoidea. La emplearemos debido a que es una configuración muy empleada y está concebida para reconocer patrones, que es lo que queremos conseguir en esta fase.

Red Perceptrón Multicapa Reconocimiento de Patrones			
Parámetros	Selección		
Función de activación	Capa oculta		Capa de salida
	Logarítmico Sigmoides		Lineal
Número de Capas (3)	• 1 entrada, 1 oculta y 1 salida		
Número de neuronas	Capa de entrada	Capa oculta	Capa de salida
	2 ⁿ (Donde n es el nivel de descomposición WP).	Variable	2

Tabla 6: Red Perceptrón Multicapa de Reconocimiento de Patrones

Red SOM

La red SOM la emplearemos como herramienta para determinar la facilidad de clasificación de la matriz que estemos empleando para clasificar, ya que no es útil en el propósito del presente Proyecto. Esto se debe al tipo de aprendizaje que caracteriza la red. Es un aprendizaje no supervisado, es decir, que no se necesita una matriz de targets que indique a la red el tipo al que pertenece la señal, sino que es capaz de encontrar y agrupar por sí misma. Esto obviamente es un procedimiento más complejo y es útil para patrones más claros que en nuestro caso.

SOM		
Parámetros	Selección	
<i>Función de activación</i>	Capa oculta	Capa de entrada
	SOM competitiva	Lineal
<i>Número de Capas (2)</i>	• 1 entrada y 1 oculta	
<i>Número de neuronas</i>	Capa de entrada	Capa oculta
	2 ⁿ (Donde n es el nivel de descomposición WP).	10x10 neuronas

Tabla 7: Red SOM

4.2.4 ENTRENAMIENTO, SIMULACIÓN Y TEST

Para realizar el entrenamiento de cada tipo de red dispondremos de 240 entradas correspondientes cada uno a cada señal, de distintos tamaños según el análisis que estemos realizando, de los cuales los sesenta primeros corresponden a señales de rodamientos sanos, los sesenta siguientes a rodamientos con defecto en pista interna, a continuación sesenta correspondientes a señales de rodamientos con defecto en pista externa y por último sesenta inputs de señales de rodamientos con defecto en bola.

También generaremos una matriz de targets, en la que empleando ceros y unos le decimos a la red de qué tipo de output es cada señal. Un ejemplo para ocho entradas y cuatro objetivos sería el mostrado en la tabla 8.

	Inp.1	Inp.2	Inp.3	Inp.4	Inp.5	Inp.6	Inp.7	Inp.8
SANO	1	1	0	0	0	0	0	0
INNER	0	0	1	1	0	0	0	0
OUTER	0	0	0	0	1	1	0	0
BOLA	0	0	0	0	0	0	1	1

Tabla 8: Ejemplo tabla de Targets

Para conocer el desarrollo del entrenamiento se deberá prestar atención al modo de desarrollo. Para ello contamos con la gráfica que nos indica el error que se genera en cada iteración. Esta gráfica es similar a la mostrada en la ilustración 58.




Ilustración 58: Ejemplo entrenamiento de red

La línea azul representa el error del entrenamiento, mientras que la verde y la roja representa el error que se esperará obtener en caso de un test para los elementos validados (verdes) y fallidos (rojos) en el test.

Una vez entrenada la red neuronal se procede a su simulación para comprobar cómo ha acertado agrupando cada entrada con su objetivo. Para ello se emplea la matriz de confusión. Ésta consiste en una matriz en la que las filas corresponden a las salidas (outputs) y las columnas a los objetivos. Con los objetivos le decimos a la red la condición de operación de la entrada, mientras que con las salidas, la matriz nos dice a nosotros el tipo de condición de operación que la red cree que es. Las casillas verdes corresponden a la concordancia entre lo que le decimos y lo que nos dice. La red estará “de acuerdo con nosotros”. La ilustración 59 representa una matriz de confusión de un entrenamiento de red en base radial.

Confusion Matrix				
Output Class	1	2	3	4
	60 25.0%	0 0.0%	0 0.0%	0 0.0%
	0 0.0%	60 25.0%	0 0.0%	0 0.0%
	0 0.0%	0 0.0%	60 25.0%	0 0.0%
	0 0.0%	0 0.0%	0 0.0%	60 25.0%
Target Class				
1	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
2	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
3	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
4	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%

Ilustración 59: Matriz de confusión de la simulación

Esta matriz sería un ejemplo de entrenamiento aparentemente perfecto, ya que como veremos más adelante, en el capítulo 5, clasificación correcta es una condición necesaria pero no definitiva, ya que debe ir acompañada de un error acorde. El funcionamiento de la matriz se observa en este ejemplo. Se introducen sesenta señales de cada condición de operación y se le dice a la red (mediante targets) de cuál de ellas se trata cada una. La red es capaz de encontrar relaciones entre ellas que las asemejan y las diferencian del resto y las agrupa como salidas.

Una vez la red se encuentre entrenada y su simulación dé como resultado valores aceptables se procederá a realizar un test muy básico. El test constará de cuatro partes, cada una de ellas correspondiente a cada tipo de condición de operación. Se realizará una simulación con veinte señales de un mismo tipo acompañados de una matriz de objetivos, siempre igual en los cuatro test. Esta matriz de objetivos será como preguntarle a la red: ¿De qué tipo son las señales que te estoy introduciendo? Esto se debe a la configuración de esta matriz. En ella nos ponemos en el hipotético caso de que desconocemos el tipo de señal que introducimos, en este caso veinte señales obtenidas de la máquina. A pesar de que sabemos que son de un tipo, en la matriz de objetivos ponemos que de las veinte, las cinco primeras son de rodamiento sano, las cinco segundas a defecto en pista interna, y así hasta completar la matriz de targets. Al simular la red nos deberá entregar como resultado las salidas agrupadas en la fila correspondiente, cinco por cuadrícula, como muestra la ilustración 60.




Ilustración 60: Matriz de confusión del test 3

En este ejemplo la matriz dice que todos los datos introducidos corresponden a rodamientos con defecto en pista externa. En la cuadrícula (3,1) se ven cinco señales. Se le dijo a la red neuronal que eran señales de rodamiento sano (target 1), pero ella nos dice que se corresponden con rodamiento con defecto en pista externa (output 3), y así ocurre con los demás.

Se realizarán para cada entrenamiento cuatro simulaciones similares a esta, una para cada tipo de salida, ya que deberemos conocer la calidad de la red al reconocer cada tipo de señal. Mostraremos los resultados como se muestra en la Ilustración 61:




Ilustración 61: Ejemplo de agrupación de los resultados de clasificación: 1: Rodamiento sano. 2: Defecto en pista interna. 3: Defecto en pista externa. 4: Defecto en bola

CAPÍTULO 5: Resultados

En el Capítulo 5 se presentarán los resultados obtenidos para los cuatro casos mencionados anteriormente: señal íntegra, paquete wavelet reconstruido, coeficientes del paquete wavelet, y por último, energía del paquete wavelet.

Se tratará de clasificar para cada caso con diferentes tipos de redes neuronales. Concretamente se emplearán redes de base radial, redes perceptrón multicapa y redes SOM.

5.1 Clasificación de la Señal Íntegra

Como primer análisis intentaremos clasificar directamente las señales obtenidas del programa de adquisición y tratadas para separarlas.

A continuación mostramos cuatro ejemplos del tipo de señal que trataremos de clasificar en la ilustración 62.




Ilustración 62: Señales típicas de los rodamientos analizados

A primera vista existen diferencias entre ellas como amplitudes diferentes o picos que hacen que podamos diferenciarlas.

Sin embargo estas diferencias no son constantes para todas las señales, por lo que al no ser denominador común de cada tipo de señal es imposible reconocer a simple vista un tipo de defecto u otro con la señal íntegra.

A continuación veremos si es posible, ya que nosotros no podemos, que un ordenador las identifique mediante el desarrollo realizado en este Proyecto.

Red de base radial

Para este análisis la red es capaz de comenzar, pero el ordenador se queda sin memoria a partir de 100 neuronas y con un error de 10^{-1} . Esto es insuficiente para obtener cualquier tipo de resultado válido por lo que no podremos realizar el análisis de red neuronal en base radial para la señal íntegra.

Red perceptrón multicapa feedforward

La red feedforward necesita una gran capacidad de memoria para el aprendizaje, y dado el tamaño de las señales el ordenador consume su memoria RAM, no pudiendo ofrecer ningún resultado.

Red perceptrón multicapa de reconocimiento de patrones

Al igual que la feedforward y al estar basadas ambas en redes de perceptrón multicapa requiere un entrenamiento que consume mucha memoria y por tanto no es posible su análisis. Probando la herramienta de reconocimiento de patrones igualmente nos quedamos sin memoria.

Red SOM

Las redes SOM tienen funciones de aprendizaje más complejas que las redes perceptrón multicapa, por lo que su análisis resulta imposible por falta de memoria.

Por lo general no es apropiado trabajar con la señal íntegra, ya que procesando la señal obtendremos parámetros característicos y simplificaremos su estructura, resultando más sencillo y rápido su tratamiento posterior.

Por tanto, dado que la señal íntegra no nos proporcionará resultados válidos deberemos someter a la señal a algún tipo de procesamiento para obtener la información concreta de la señal que nos permita clasificarlas.

Como ya explicamos anteriormente usaremos la transformada wavelet para obtener coeficientes y reconstrucciones de paquetes para los casos de CFS y RCFS y la energía contenida en ciertos paquetes para el análisis energético.

5.2 Clasificación de los Paquetes Wavelet reconstruidos (RCFS)

El siguiente paso en el intento de clasificar las señales es procesar las señales de los rodamientos con Transformadas Wavelet. En este caso se utilizará la señal reconstruida del paquete elegido del nivel deseado, obtenido mediante el Preprocesamiento Wavelet explicado en el Capítulo 3.

Como cabe esperar, ocurrirá lo mismo que para la señal íntegra, ya que las señales de gran tamaño (alrededor de un megabyte cada una), dejando al sistema sin memoria RAM e impidiendo obtener resultados.

Esto descarta el análisis desde el punto de vista de recursos informáticos, pero el análisis podría ser válido para la clasificación, por tanto antes de descartarlo definitivamente analizaremos un poco más en detalle el método.

Para ello al igual que con la señal íntegra se analizará la forma de las señales reconstruidas a diferentes niveles intentando encontrar algún tipo de patrón redundante con el tipo de rodamiento.

Se emplearán muestras de veinte señales procesadas por cada condición de operación, con una Wavelet Daubechies 6 en paquete 29 del nivel de descomposición 5, en el paquete 145 del nivel de descomposición 8 y en el paquete 554 del nivel de descomposición 10, que son los paquetes con mayor diferencia energética con respecto a la señal de rodamientos sanos y apoyados en la gráfica de energías para evitar solapamientos.

Los resultados gráficos se mostrarán desde la ilustración 63 a la 74. En cada una de ellas se podrá apreciar como existen diferencias sustanciales entre las señales del mismo grupo.




Ilustración 63: Muestra de 20 señales reconstruidas de rodamientos sanos del paquete wavelet 29 del nivel 5 de una transformada Daubechies db6

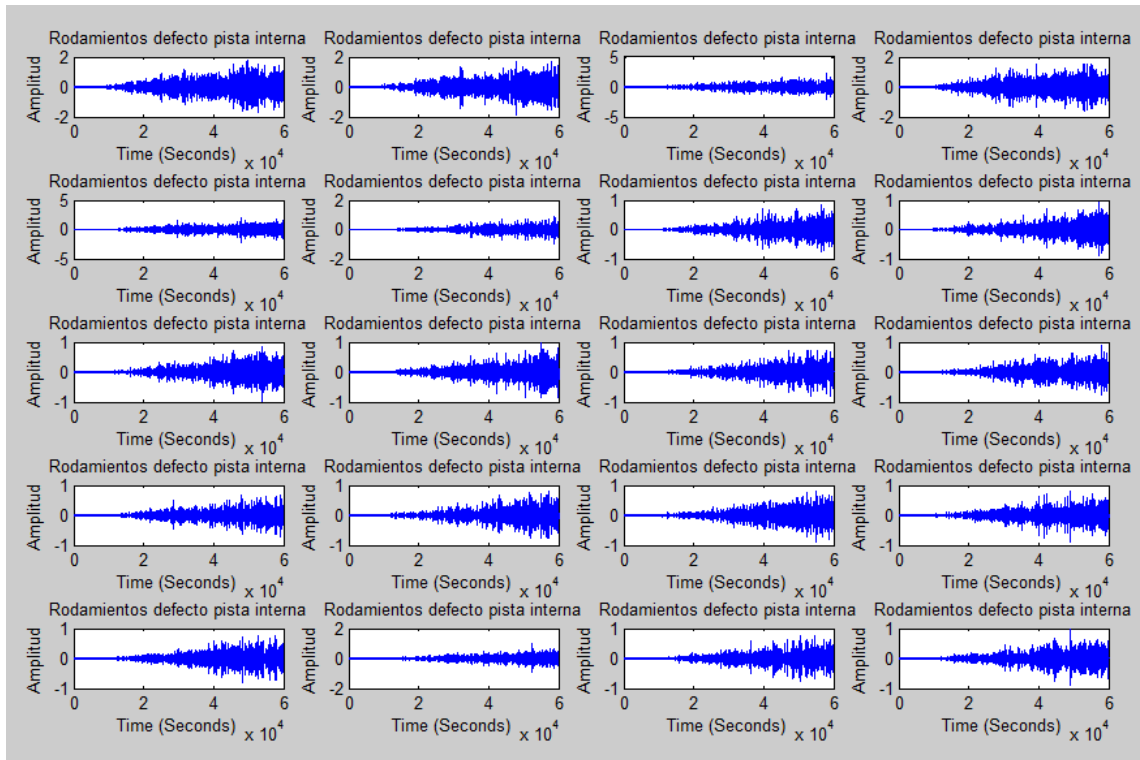


Ilustración 64: Muestra de 20 señales reconstruidas de rodamientos sanos del paquete wavelet 29 del nivel 5 de una transformada Daubechies db6

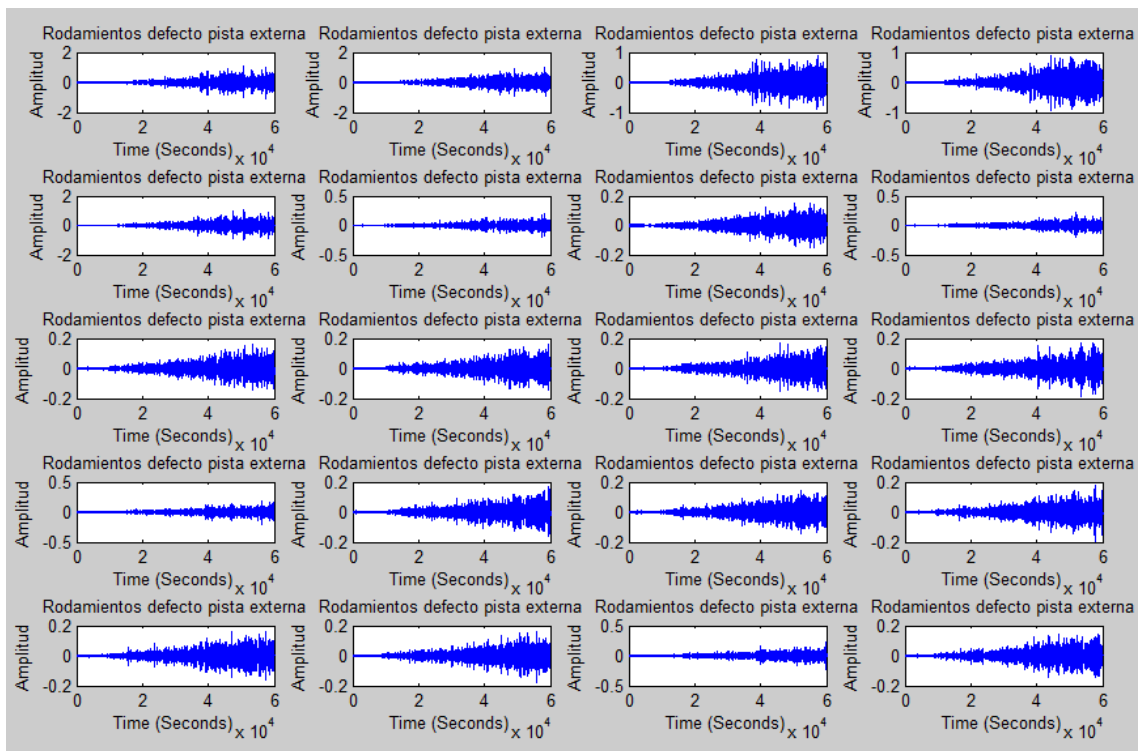


Ilustración 65: Muestra de 20 señales reconstruidas de rodamientos con defecto en pista externa del paquete wavelet 29 del nivel 5 de una transformada Daubechies db6

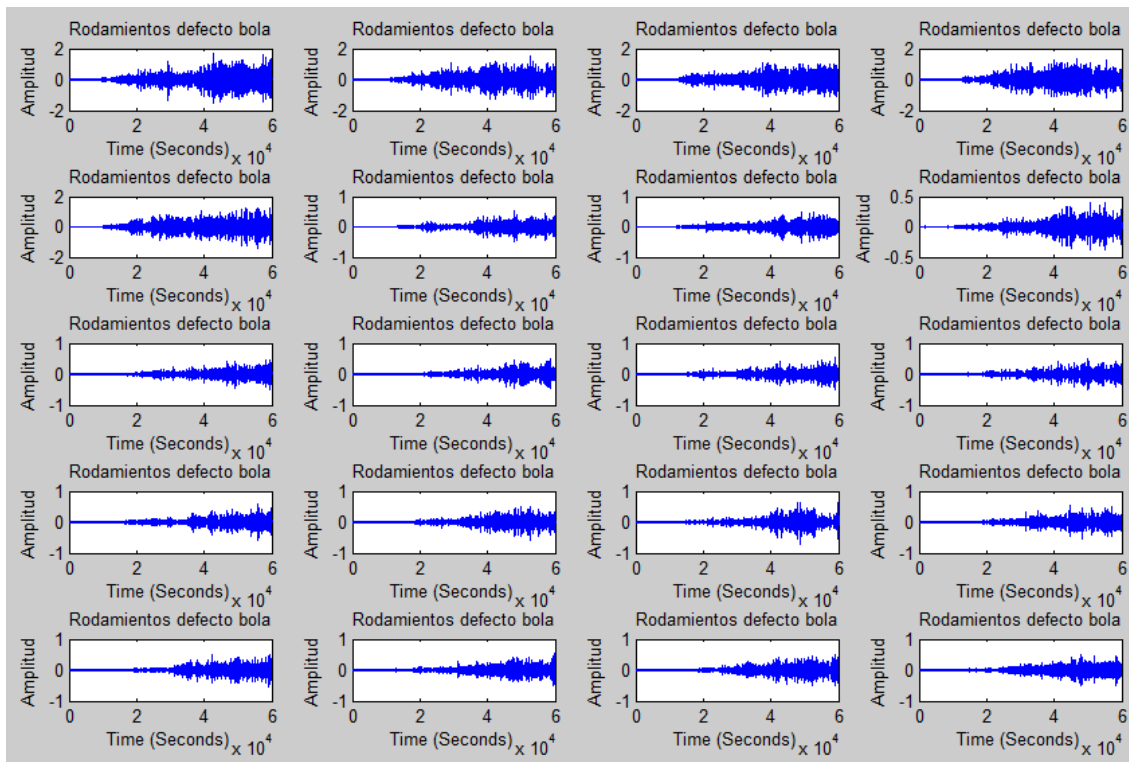


Ilustración 66: Muestra de 20 señales reconstruidas de rodamientos con defecto en bola del paquete wavelet 29 del nivel 5 de una transformada Daubechies db6

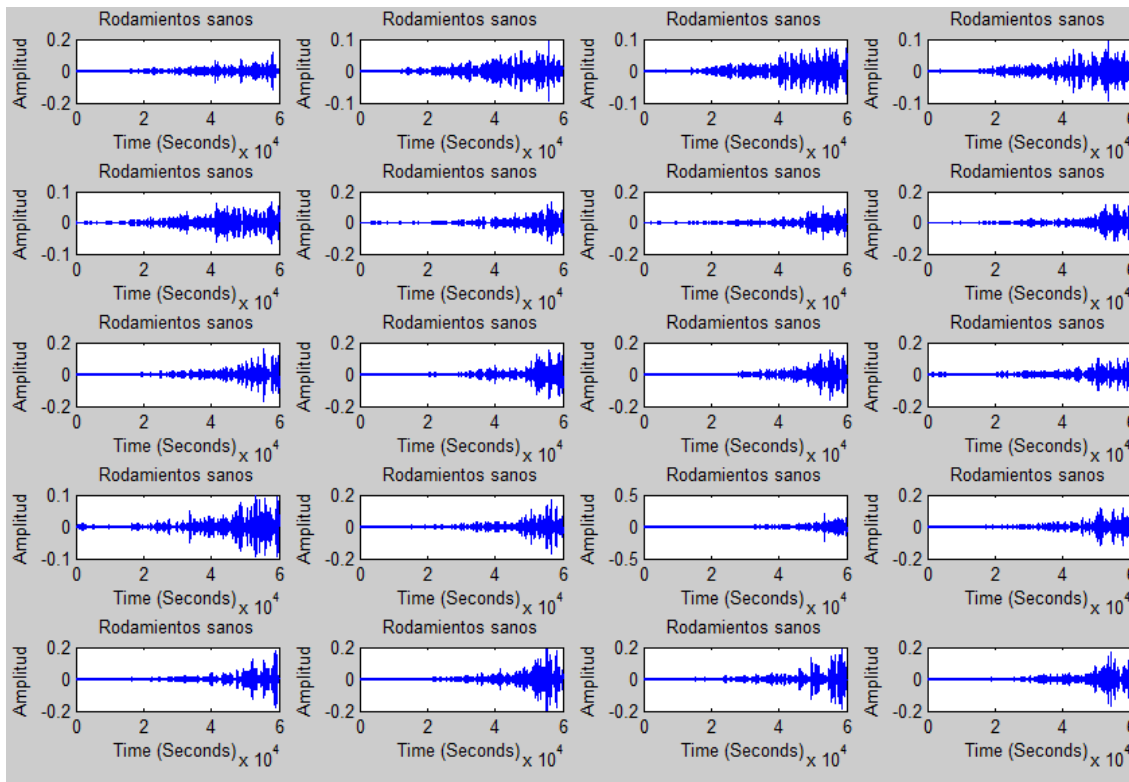


Ilustración 67: Muestra de 20 señales reconstruidas de rodamientos sanos del paquete wavelet 145 del nivel 8 de una transformada Daubechies db6

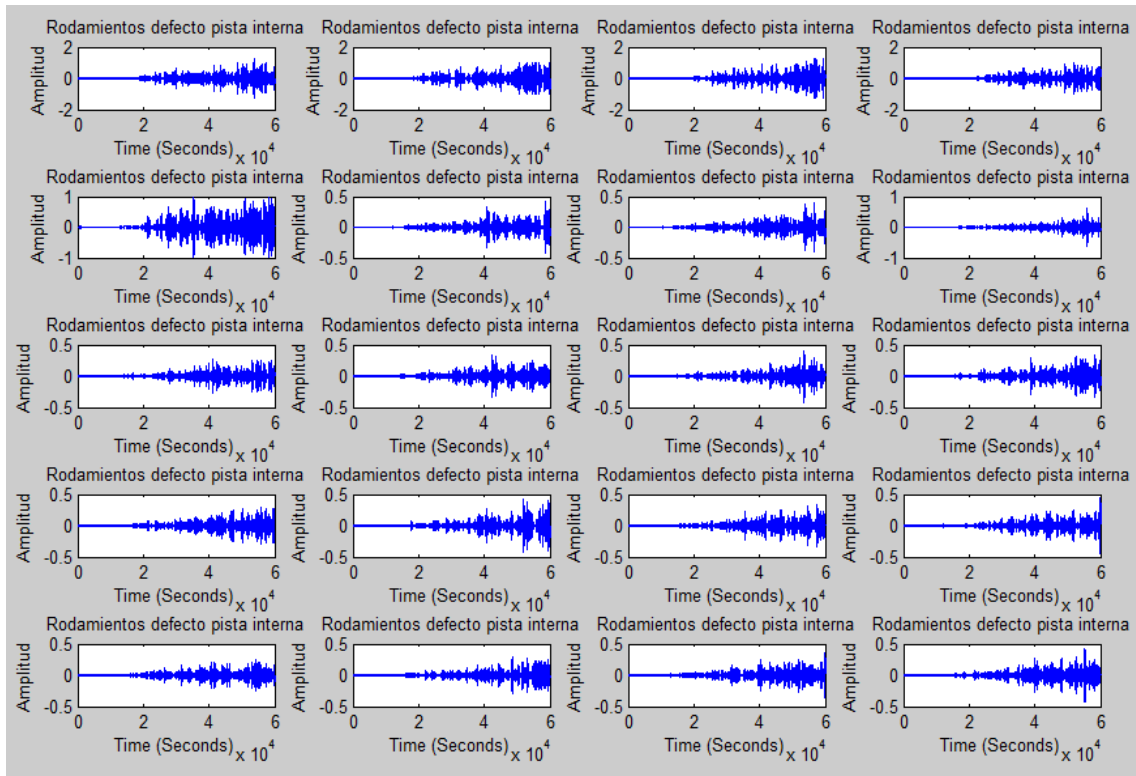


Ilustración 68: Muestra de 20 señales reconstruidas de rodamientos con defecto en pista interna del paquete wavelet 145 del nivel 8 de una transformada Daubechies db6

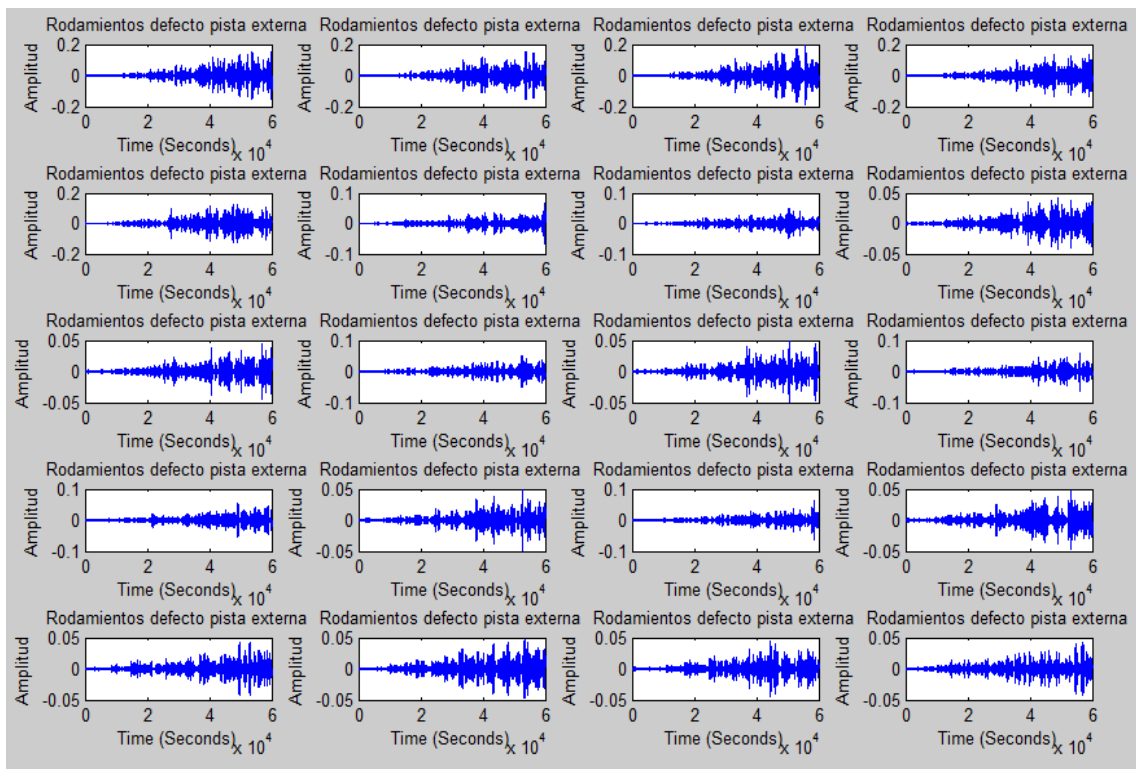


Ilustración 69: Muestra de 20 señales reconstruidas de rodamientos con defecto en pista externa del paquete wavelet 145 del nivel 8 de una transformada Daubechies db6

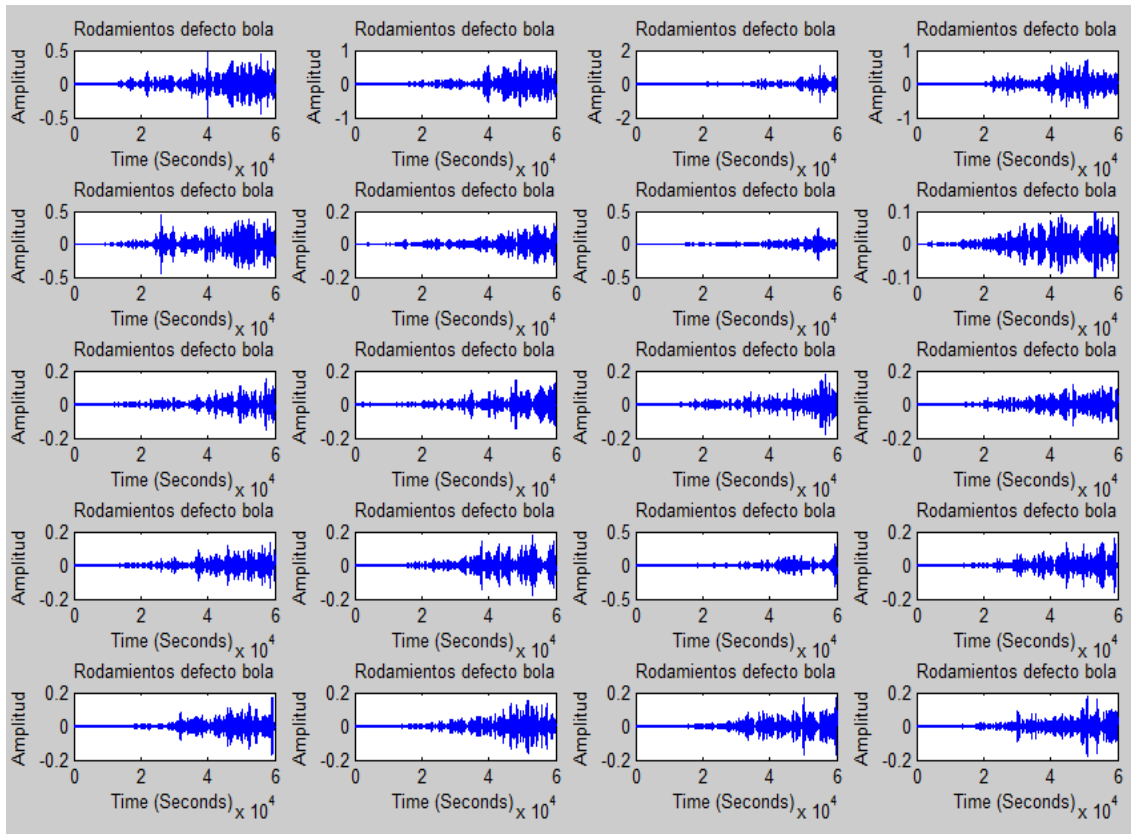


Ilustración 70: Muestra de 20 señales reconstruidas de rodamientos con defecto en bola del paquete wavelet 145 del nivel 8 de una transformada Daubechies db6

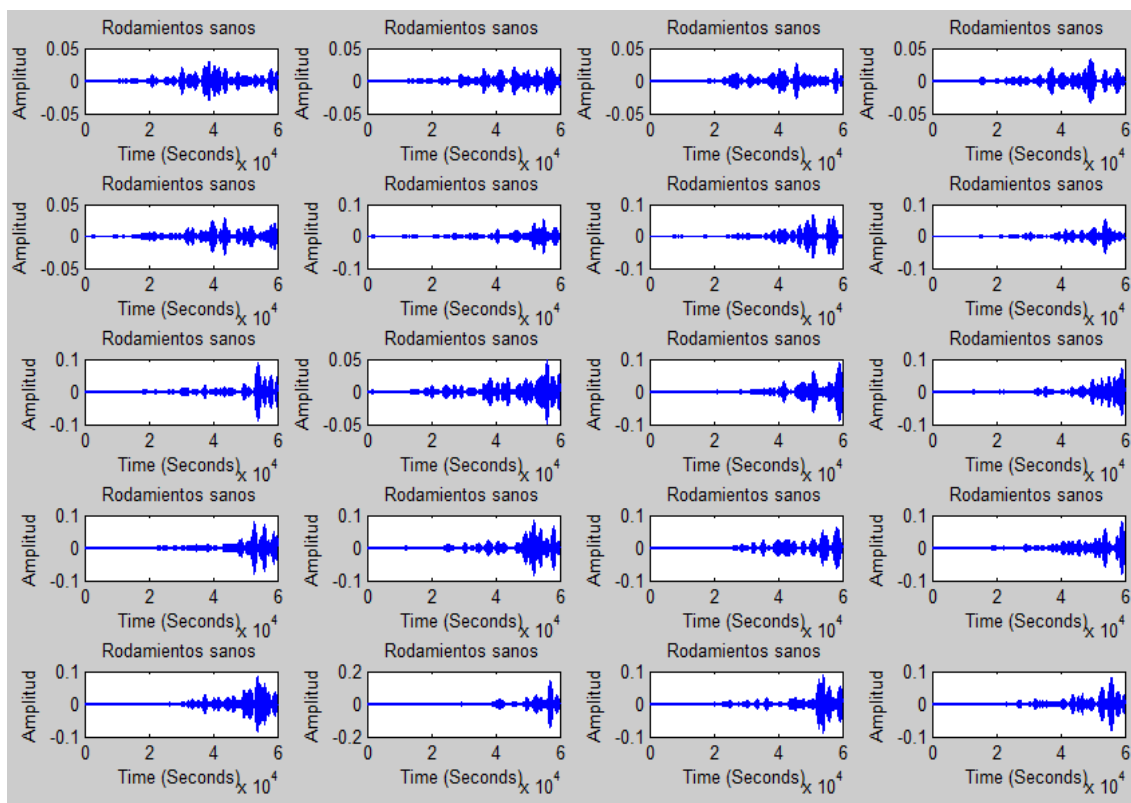


Ilustración 71: Muestra de 20 señales reconstruidas de rodamientos sanos del paquete wavelet 554 del nivel 10 de una transformada Daubechies db6

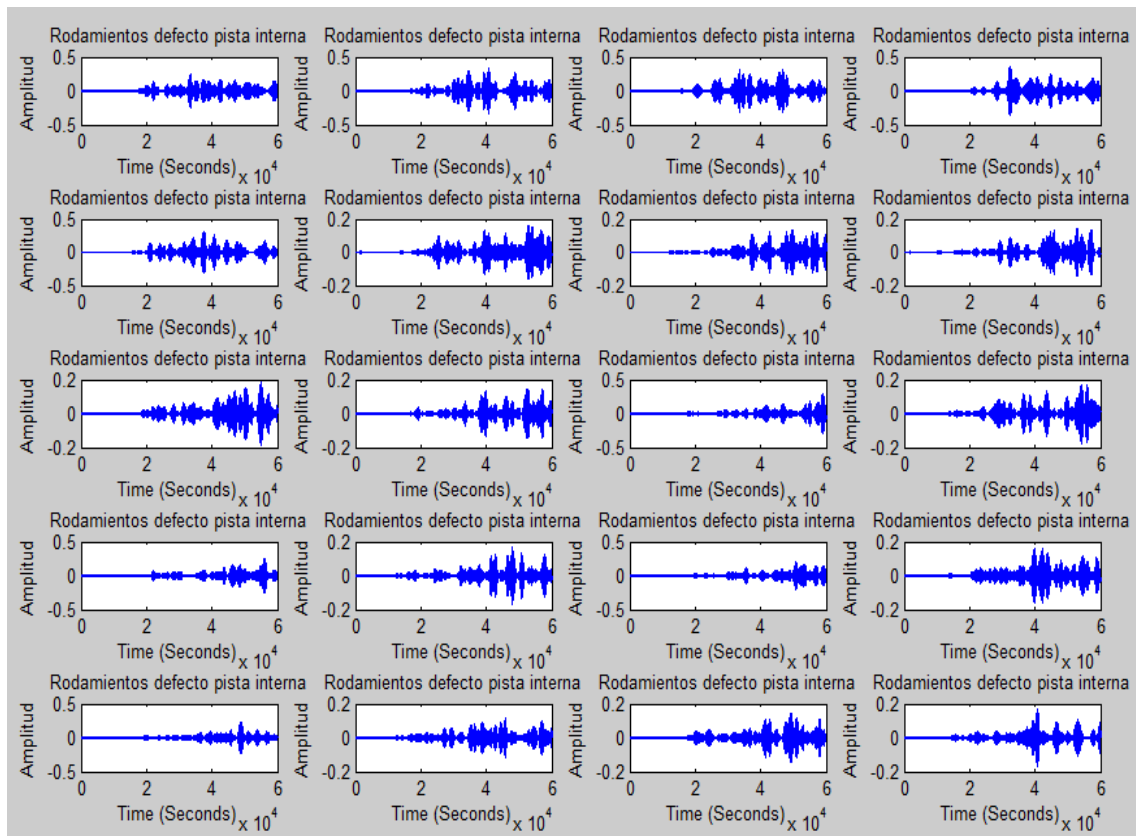


Ilustración 72: Muestra de 20 señales reconstruidas de rodamientos con defecto en pista interna del paquete wavelet 554 del nivel 10 de una transformada Daubechies db6

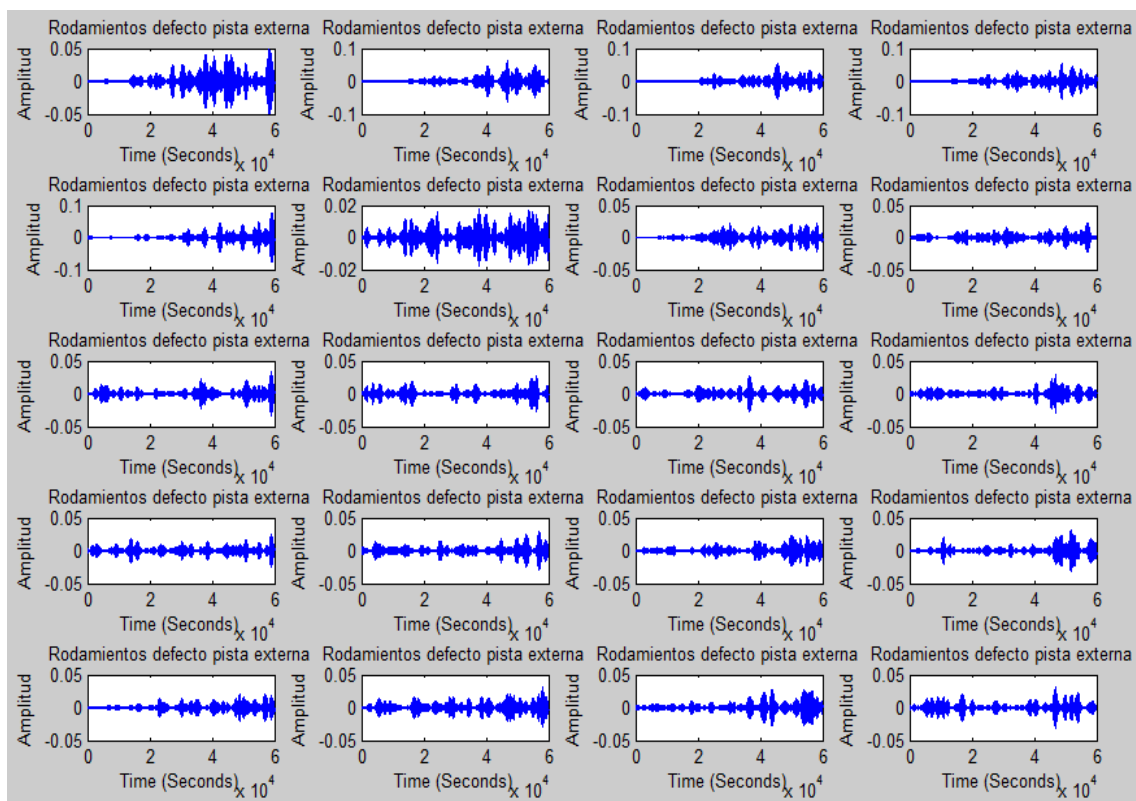


Ilustración 73: Muestra de 20 señales reconstruidas de rodamientos con defecto en pista externa del paquete wavelet 554 del nivel 10 de una transformada Daubechies db6

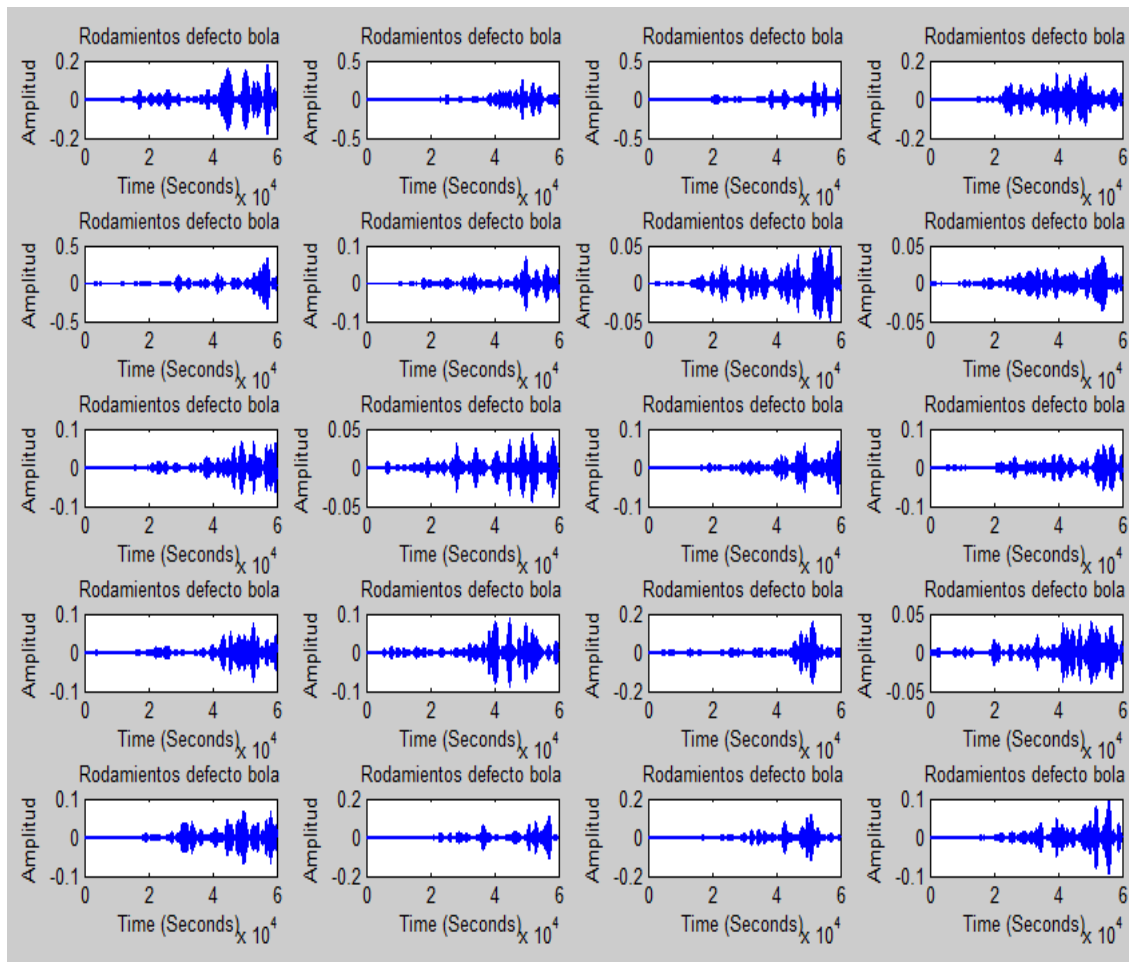


Ilustración 74: Muestra de 20 señales reconstruidas de rodamientos con defecto en bola del paquete wavelet 554 del nivel 10 de una transformada Daubechies db6

A primera vista se puede descartar directamente el nivel cinco ya que la señal sigue siendo muy similar a la original y el resultado variaría poco respecto al obtenido para la señal íntegra.

En nivel ocho se aprecian zonas concretas en las que la señal se amplifica, y esto se hace muy evidente en las de nivel de descomposición 10. Sin embargo no existe un patrón constante para las señales de un mismo tipo y difieren tanto en amplitud como en tiempo. Esto se debe principalmente carácter aleatorio y no estacionario del proceso en sí, aparecen fenómenos diferentes en cada toma de muestras que pueden afectar a la señal, como la temperatura del equipo, ruido u otras vibraciones externas (o internas como la mampara protectora) que son muy difíciles de reconocer y asilar.

Por tanto aunque es un análisis interesante no podemos clasificar las señales empleando este método.

5.3 Clasificación de los Coeficientes del paquete Wavelet (CFS)

La clasificación de señales a partir de los coeficientes wavelet es un método que ha dado muy buenos resultados en clasificación de señales con excitación estacionaria, por lo que resulta interesante comprobar su eficacia en el caso de señales transitorias [7].

Para ello como se explicó anteriormente se obtendrán en el preprocesamiento wavelet los niveles que nos permiten diferenciar en mayor grado nuestras condiciones de operación. Se elegirán los mejores paquetes de los que calcularemos sus coeficientes wavelet y trataremos de clasificar.

Se actuará en tres niveles de descomposición wavelet, el cinco, el ocho y el diez, ya que antes y después de estos niveles las señales son más difusas. En estos niveles calcularemos uno o dos paquetes para los distintos tipos de redes que decidimos entrenar.

Se mostrarán los resultados del entrenamiento y, en caso de que proceda, de la simulación, analizando los resultados obtenidos en cada caso.

Por último se utilizará una nomenclatura estándar para estos análisis denominándolos del siguiente modo:

Análisis “Tipo” “Nivel”. “Número”: “Descripción básica”

NIVEL 5

	Inner	Outer	Ball
Mejor paquete	18	8	18
2º mejor paquete	19	29	29
3º mejor paquete	29	31	31
4º mejor paquete	17	21	20
5º mejor paquete	16	22	2

Tabla 9: Mejores paquetes wavelet

Analizaremos para el nivel 5 de descomposición el paquete 18 y el 29 ya que en principio aparentan ser los dos mejores niveles según el procesamiento Wavelet.

En la gráfica de la ilustración 75 observamos la energía de cada paquete wavelet de cada señal y nos sirve como ayuda complementaria al procesamiento Wavelet.




Ilustración 75: Gráfica de energías. Nivel de descomposición 5

En la gráfica de energías podemos corroborar que en el nivel 18 y en el 29 las señales están claramente diferenciadas y podremos encontrar un patrón de clasificación.

Análisis CFS 5.1: CFS nivel 5 paquete 29. RBF

Entrenamiento




Ilustración 76: Entrenamiento del Análisis CFS 5.1

Cuando alcanzamos 234 neuronas el error cae bruscamente como muestra la ilustración 76. Esto no es un buen indicativo ya que al adjudicar una neurona por input a cada una le adjudica una función gaussiana y la asocia perfectamente con su target, pero no será capaz de identificar señales nuevas de entrada. Para que la red radial sea válida en su entrenamiento el error deberá disminuir mucho más antes de alcanzar las 240 neuronas. Sin embargo la ilustración 77 nos dice que el entrenamiento a sido correcto, confirmando la hipótesis mencionada anteriormente.





Ilustración 77: Matriz de confusión del entrenamiento del Análisis CFS 5.1

Simulación

Para la simulación se prueba cada tipo condición de operación de los rodamientos que podemos tener. Para ello introducimos una señal de veinte muestras de un mismo tipo y le digo a la red neuronal mediante una matriz de targets que cinco son de rodamiento sano, cinco son con defecto en pista interna, cinco con defecto en pista externa y cinco con defecto en bola.






Ilustración 78: Matrices de confusión de la simulación del Análisis CFS 5.1

Sin embargo la red nos dice que en todos los casos las señales introducidas corresponden a rodamiento con defecto en pista externa (output 3) a través de las matrices de confusión de la ilustración 78, por tanto en esta situación la red carece de fiabilidad.

Análisis CFS 5.2: CFS nivel 5 paquete 18. RBF

El desarrollo del análisis es prácticamente idéntico al anterior, por lo que al no apreciarse diferencia sustancial respecto al análisis CFS 5.1. queda descartado.

Análisis CFS 5.3: CFS nivel 5 paquete 18. Feedforward. 240 neuronas.

Entrenamiento




Ilustración 79: Análisis CFS 5.3: CFS nivel 5 paquete 18





Ilustración 80: Matriz de confusión del entrenamiento del Análisis CFS 5.3

Los resultados del entrenamiento no son muy alentadores ya que el error cometido es demasiado elevado y la tasa de acierto es del 49,6% según los datos de las ilustraciones 79 y 80. En este caso el entrenamiento finaliza por suceder veinte validaciones consecutivas. Si se observa detenidamente la ilustración 80 se podría concluir que lo que ha sucedido es que la red ha interpretado en su mayoría las señales como defecto en pista externa, por tanto, en el momento en que éstas entran realmente en la red, una tras otra serán aciertos y la red finaliza el entrenamiento.

Simulación






Ilustración 81: Matrices de confusión de la simulación del Análisis CFS 5.3

Como consecuencia del entrenamiento los porcentajes de clasificación son demasiado bajos en la simulación: Tenemos un 35% de acierto para rodamiento sano, un 40% para pista interna, un 60% en pista externa y únicamente un 5% en bola, ya que confunde la mayoría de las señales con defectos en pista externa.

Análisis CFS 5.4: CFS nivel 5 paquete 29. Feedforward. 240 neuronas.

Al igual que ocurrió en la red de base radial el hecho de clasificar otro paquete genera resultados similares a los obtenidos para el mismo tipo de red y paquete 18. Por tanto en este caso no es una opción mejor.

Análisis CFS 5.5: CFS nivel 5 paquete 29. Feedforward. Dos capas ocultas 240x24.

Una primera capa con 240 neuronas con función de transferencia tangente hiperbólica (“tansig” en MATLAB) y una segunda capa con 24 neuronas y función de transferencia lineal. Los resultados en este caso no mejoran los obtenidos para una capa oculta.

Análisis CFS 5.6: CFS nivel 5 paquete 18. Rec. Patrones. 240 neuronas.

Entrenamiento




Ilustración 82: Resultados del entrenamiento del Análisis CFS 5.6





Ilustración 83: Matriz de confusión del entrenamiento del Análisis CFS 5.6

Los resultados son notablemente peores que para el caso de red perceptrón multicapa feedforward tras los resultados del entrenamiento (ilustraciones 82 y 83). Esta red parece ser más inestable en el entrenamiento que la anterior, por tanto sus resultados son impredecibles para este supuesto.

Simulación






Ilustración 84: Matrices de confusión de la simulación del Análisis CFS 5.6

Los resultados del entrenamiento (ilustraciones 82 y 83) y la simulación (ilustración 84) son muy negativos y carecen de sentido y credibilidad por lo que este análisis queda completamente descartado.

Análisis CFS 5.7: CFS nivel 5 paquete 29. Rec. Patrones. 240 neuronas.

Al igual que en los casos anteriores la clasificación da resultados similares que para el paquete 18, por lo que no existe mejora alguna debido al análisis de otro paquete.

Análisis CFS 5.8: CFS nivel 5 paquete 18. SOM. Red de 10x10 neuronas

La ilustración 85 representa las neuronas de la capa oculta de la red SOM. Según el entrenamiento sucede, los pesos se distribuyen en la capa por cada una de las neuronas, agrupándose o diferenciándose en distintas zonas según la procedencia de la señal.

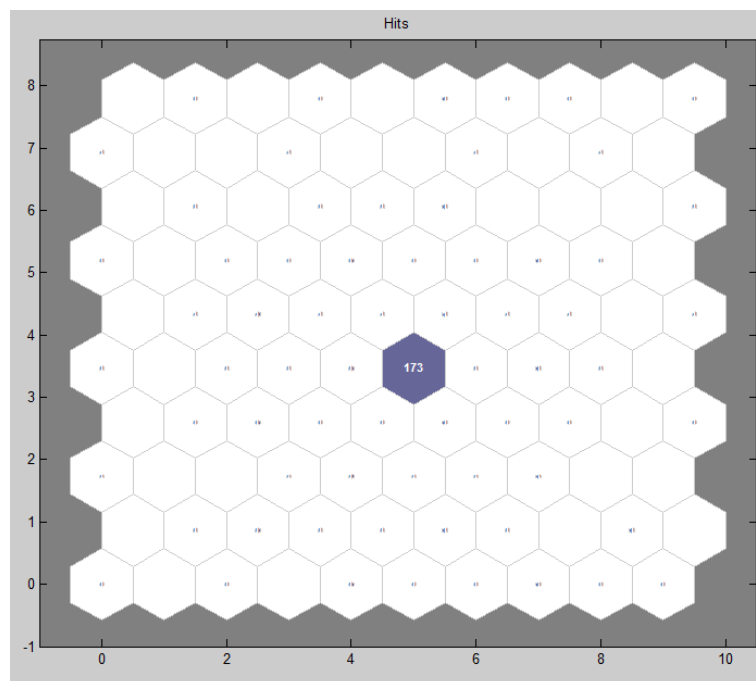


Ilustración 85: Resultados del entrenamiento del Análisis CFS 5.8

Tras mil iteraciones la red no es capaz de diferenciar por si misma entre las 240 señales introducidas en ella, interpretando que la mayoría son iguales. Este análisis nos muestra que para los coeficientes del paquete wavelet el nivel de descomposición cinco podría no ser suficiente, por lo que se analizará un nivel de descomposición superior y bandas de frecuencia más estrechas.

NIVEL 8

Como en el caso anterior a partir de la siguiente tabla obtenemos los mejores niveles para clasificar:

	Inner	Outer	Ball
Mejor paquete	145	174	174
2º mejor paquete	183	0	170
3º mejor paquete	181	170	0
4º mejor paquete	175	175	238
5º mejor paquete	147	6	182

Tabla 10: Mejores paquetes wavelet para nivel de descomposición 8

En este caso trataremos de clasificar los coeficientes del paquete 174 y del 145, con la esperanza de que si aumentamos la precisión del análisis podamos diferenciar en mayor medida nuestras señales. La ilustración 86 representa la energía de cada paquete wavelet de cada señal para nivel de descomposición ocho.




Ilustración 86: Gráfica de energías. Nivel de descomposición 8

Esta gráfica es más difusa que el caso de nivel cinco, pero aún así se aprecian zonas en las que las señales son claramente diferenciables. Por ejemplo en torno al nivel 150, al 170 y al 195.

Análisis CFS 8.1: CFS Nivel 8 paquete 174. RBF

Entrenamiento




Ilustración 87: Resultados del entrenamiento. Análisis CFS 8.1




Ilustración 88: Matriz de confusión del entrenamiento del Análisis CFS 8.1

De momento, como muestran las ilustraciones 87 y 88, ocurrió como en el caso anterior, ya que los resultados del entrenamiento parecen ser negativos al decaer el error muy rápidamente.

Simulación




Ilustración 89: Matrices de confusión de la simulación del Análisis CFS 8.1

Ocurre lo mismo que para nivel cinco por tanto no se trata de un problema de precisión de la red, sino que la red radial no es capaz de encontrar un patrón que diferencie las señales, interpretando todo como señales procedentes de rodamientos con defecto en pista externa.

Por tanto esta red sigue sin ser útil ni precisa para el caso de análisis de coeficientes de paquete wavelet.

Análisis CFS 8.2: CFS Nivel 8 paquete 145.RBF

Ocurre lo mismo que en nivel de descomposición cinco. Los resultados no difieren del análisis anterior para el paquete 145.

Análisis CFS 8.3: CFS Nivel 8 paquete 174. Feedforward. 240 neuronas.

Entrenamiento




Ilustración 90: Resultados del entrenamiento del Análisis CFS 8.3

Confusion Matrix					
Output Class	1	2	3	4	
	36 15.0%	8 3.3%	14 5.8%	13 5.4%	50.7% 49.3%
	1 0.4%	27 11.3%	1 0.4%	3 1.3%	84.4% 15.6%
	13 5.4%	6 2.5%	29 12.1%	10 4.2%	50.0% 50.0%
	10 4.2%	19 7.9%	16 6.7%	34 14.2%	43.0% 57.0%
Target Class				1	2
				60.0% 40.0%	45.0% 55.0%
				48.3% 51.7%	56.7% 43.3%
				52.5% 47.5%	

Ilustración 91: Matriz de confusión del entrenamiento del Análisis CFS 8.3

Los resultados del entrenamiento (ilustraciones 90 y 91) no son mejores que en casos anteriores así que probaremos una red con dos capas ocultas como alternativa.

Análisis CFS 8.4: CFS Nivel 8 paquete 174. Feedforward. Dos capas ocultas 240x24

Se introducen dos capas ocultas de neuronas en lugar de una sola como se hacía anteriormente. Su topología se muestra en la ilustración 92.




Ilustración 92: Configuración de la red neuronal del Análisis CFS 8.4

Una primera capa con 240 neuronas con función de transferencia tangente hiperbólica (“tansig” en MATLAB) y una segunda capa con 24 neuronas y función de transferencia lineal.

En principio este tipo de análisis no está recomendado para estos casos [14,15] ya que se añaden numerosas variables al problema y la red es mucho más difícil de afinar. Se deberían variar el número de neuronas y las funciones de transferencia de dos capas ocultas, dando lugar a múltiples posibilidades. Los resultados del entrenamiento se representan en las ilustraciones 93 y 94.

Entrenamiento




Ilustración 93: Resultados del entrenamiento del Análisis CFS 8.4

En este caso concreto la red consigue realizar un mayor número de iteraciones que en el caso anterior, disminuyendo el error hasta órdenes de magnitud de 10^{-2} . Sin embargo los errores de validación y test son altos y no disminuyen desde la iteración 15. Esto desembocará en resultados negativos.





Ilustración 94: Matriz de confusión del entrenamiento del Análisis CFS 8.4

Los resultados de clasificación del entrenamiento son esperanzadores pero como vimos en el gráfico de entrenamiento la validación y el test no indican un buen entrenamiento.

Simulación






Ilustración 95: Matrices de confusión de la simulación del Análisis CFS 8.4

La simulación (ilustración 94) confirma las hipótesis. En este caso al emplear una segunda capa conseguimos un mejor entrenamiento de la red neuronal. Sin embargo no nos deja alcanzar bajos errores lo que afecta, como se aprecia, al test final.

Análisis CFS 8.5: CFS Nivel 8 paquete 174. Rec.patrones. 240 neuronas.

La red tiene los mismos problemas que la de nivel cinco de descomposición, ya que en el entrenamiento sigue agrupando todas las entradas en un mismo grupo.

Análisis CFS 8.6: CFS Nivel 8 paquete 174. SOM. Red 10x10 neuronas

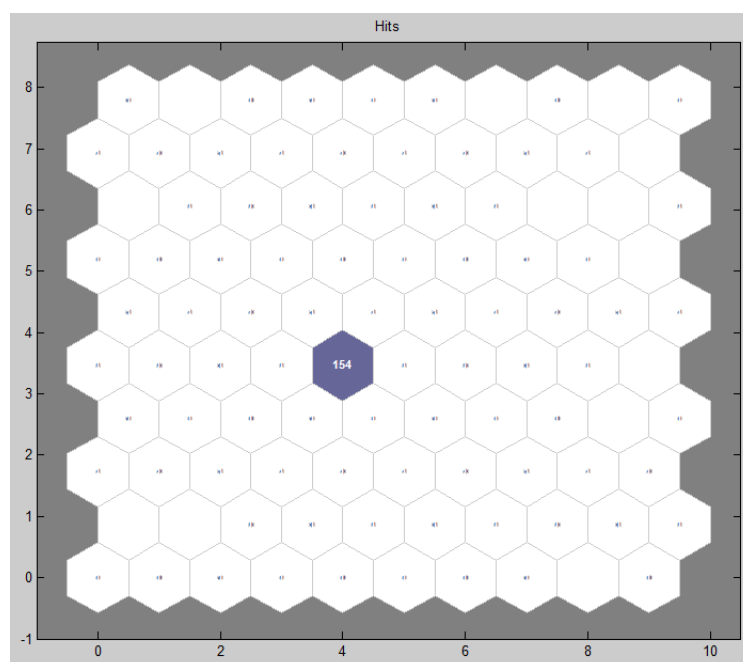


Ilustración 96: Resultados del entrenamiento del Análisis CFS 8.6

Como vemos en la ilustración 96, la red SOM es incapaz de establecer diferencias aparentes entre las señales de entrada, aunque el resultado es ligeramente mejor que en nivel cinco ya que el agrupamiento es menor.

NIVEL 10

Tras los resultados obtenidos previamente, el análisis de coeficientes queda prácticamente descartado. Aún así realizaremos un último análisis en nivel diez de descomposición para concluir que no se trata de un problema de afinar el punto preciso, sino que el análisis en sí no es concluyente.

	Inner	Outer	Ball
Mejor paquete	0	698	698
2º mejor paquete	698	0	0
3º mejor paquete	732	896	896
4º mejor paquete	692	702	702
5º mejor paquete	581	581	581

Tabla 11: Mejores paquetes wavelet. Nivel 10

Analizaremos únicamente el nivel 698 ya que no parece ser necesario prolongar más este análisis. Partiremos como en los casos anteriores de la tabla 11 y la ilustración 97.




Ilustración 97: Gráfica de energías. Nivel 10

En este caso existe un gran solapamiento por lo que lo más probable es que no encontremos análisis mejores que los anteriores. El motivo es que cuanto más precisamos la energía es menor y por tanto la diferencia de energía entre niveles disminuye.

Análisis CFS 10.1: CFS nivel 10 paquete 698 RBF

Nos aporta resultados similares a los obtenidos para nivel cinco y ocho, por lo que hemos de suponer que a pesar de afinar más no obtendremos mejores resultados para red en base radial.

Análisis CFS 10.2: CFS nivel 10 paquete 698. Feedforward. Dos capas ocultas 240x24

Al igual que en el caso anterior ya no estamos obteniendo mejores resultados. En este caso el resultado del entrenamiento es muy similar dando un porcentaje de clasificación de en torno a 70%.

Los resultados de simulación siguen sin darnos ninguna fiabilidad, como se muestra a continuación en la ilustración 98.

Simulación

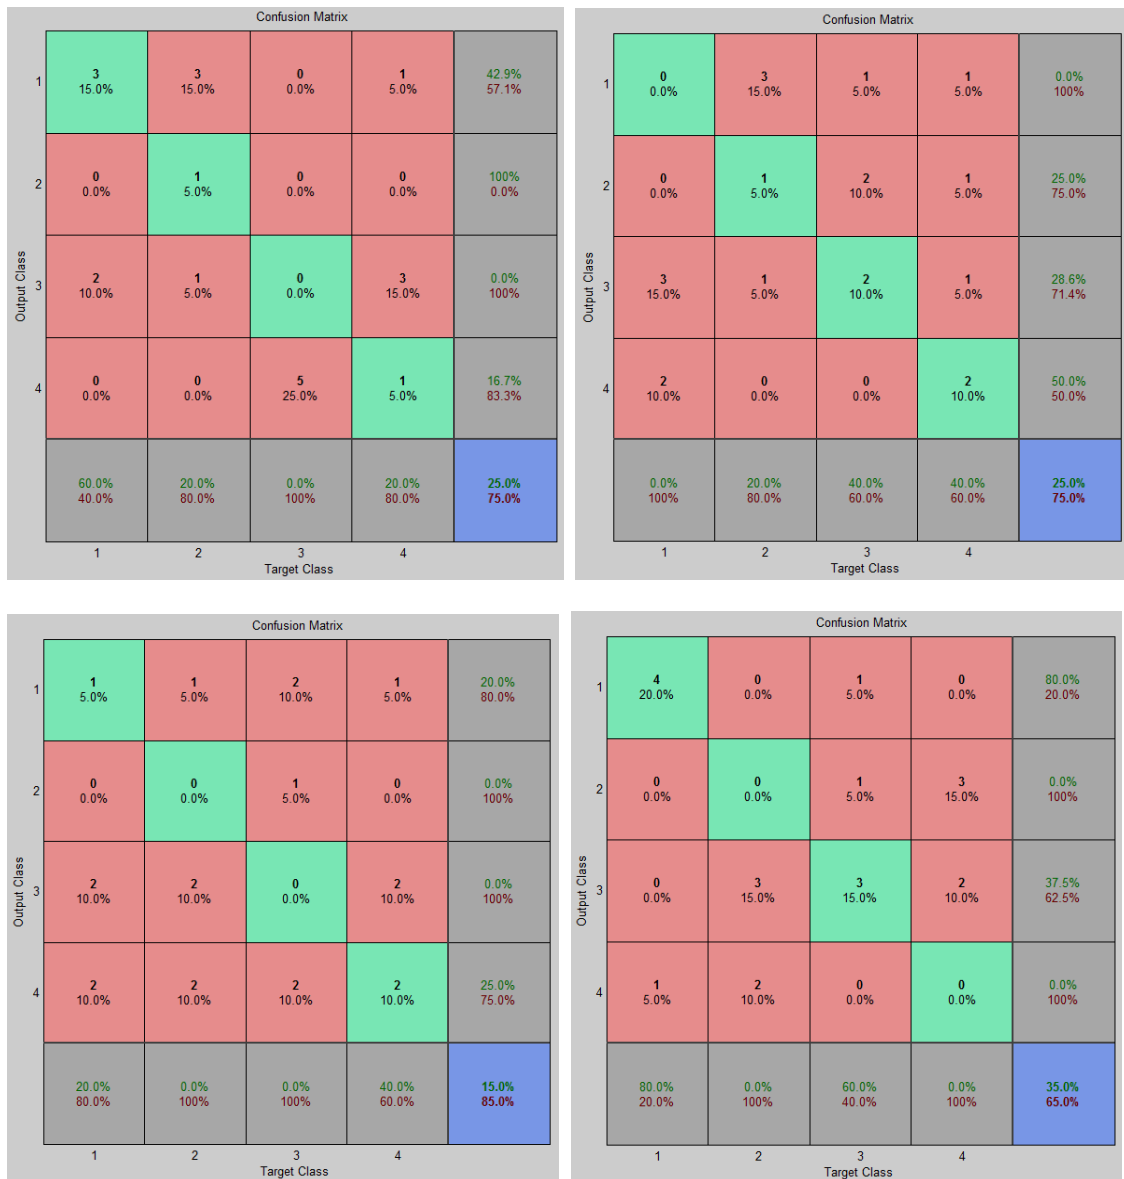


Ilustración 98: Matrices de confusión de la simulación del Análisis CFS 10.2

Análisis CFS 10.3: CFS Nivel 10 paquete 698. Rec.patrones. 240 neuronas.

La red tiene los mismos problemas que la de nivel cinco y ocho, por tanto este análisis queda totalmente descartado para los coeficientes del paquete wavelet.

Análisis CFS 10.4: CFS Nivel 10 paquete 698. Red 10x10 neuronas

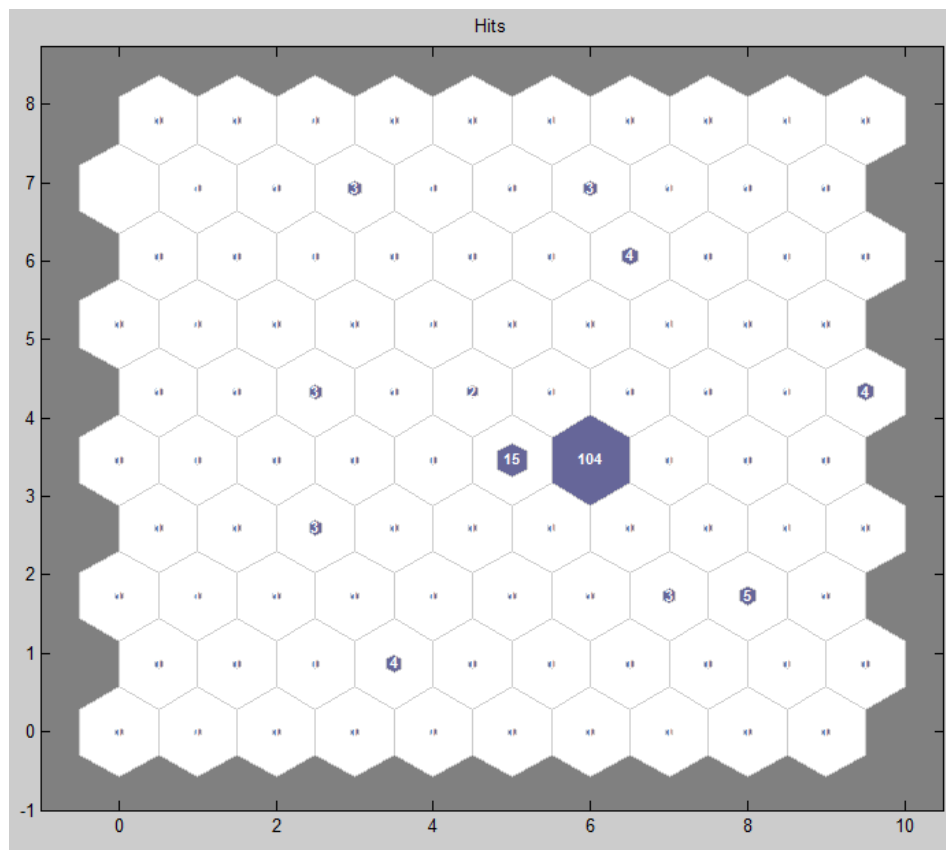


Ilustración 99: Resultados del entrenamiento del Análisis CFS 10.4

El entrenamiento no supervisado (ilustración 99) es capaz de diferenciar en mayor medida que en los niveles anteriores (ilustraciones 85 y 96). Este análisis o aporta resultados ni tampoco interesa, sin embargo, de él se pueden sacar conclusiones. Por ejemplo nos indica que los datos son más diferenciables y agrupables en distintos conjuntos que para los casos anteriores. Por tanto será más sencilla su clasificación en un entrenamiento supervisado. Sin embargo seguimos teniendo 104 de los 240 entradas agrupadas. Por tanto deberemos buscar otro tipo de análisis que nos dé mejores resultados.

CONCLUSIÓN

El método de clasificación de señales a partir de los coeficientes del paquete wavelet no es eficaz a la hora de clasificar este tipo de señal transitoria para los paquetes que el preprocesamiento wavelet nos indica.

El problema básicamente es que si analizamos los coeficientes, éstos varían demasiado para cada señal imposibilitando asimilarlos o diferenciarlos.

Esto no quiere decir que este método no sirva para clasificar señales transitorias o incluso nuestras señales. Puede significar simplemente que los paquetes elegidos no sean los correctos y el error sea el preprocesamiento wavelet, ya que éste se realiza empleando diferencias de energías entre señales.

Por ello es de lógica tratar de clasificar las señales a partir de la energía de los paquetes ya que es realmente lo que el preprocesamiento wavelet nos indica.

5.4 Clasificación de Energía de los Paquetes Wavelet

Generamos la matriz de patrones de energía a partir de los niveles con mayor diferencia energética respecto de la señal de rodamientos sanos.

NIVEL 5

PATRÓN DE ENERGÍA	Nº paquete
Mejor paquete	18
2º mejor paquete	19
3º mejor paquete	29
4º mejor paquete	17
5º mejor paquete	16

Tabla 12: Patrón de energía empleado. Nivel 5




Ilustración 100: Gráfico de energías. Nivel 5 con los paquetes utilizados

Como se puede observar en la ilustración 100 los niveles 16, 17, 18 y 19 aparentan una diferencia notable entre las cuatro variantes de señales, mientras que en el nivel 29 la señal de rodamiento sano y la de defecto en pista externa tienen similares energías. En principio esto no debe suponer un problema ya que el patrón debería ser consistente y diferenciable para cada tipo de señal.

Análisis Energía 5.1: Energía nivel 5. RBF

Entrenamiento




Ilustración 101: Resultados del entrenamiento del Análisis Energía 5.1

Como se aprecia en el entrenamiento (ilustraciones 101) el error converge progresivamente hasta alcanzar el valor objetivo de $1 \cdot 10^{-5}$ con 171 neuronas. La diferencia con el entrenamiento correspondiente de coeficientes es muy notable y se ajusta a lo que pudiésemos desear en un entrenamiento.




Ilustración 102: Matriz de confusión del entrenamiento del Análisis Energía 5.1

La simulación de las señales entrenadas (ilustración 102) nos da como resultado una clasificación perfecta, lo cual será buena señal siempre que el entrenamiento haya sido correcto, como este caso aparenta.

Simulación



Ilustración 103: Matrices de confusión de la simulación del Análisis Energía 5.1

La simulación es muy buena ya que encontramos unos porcentajes de 95% de clasificación acertada para rodamientos sanos, 80% en pista interna, 100% en pista externa y 100% en bola (ilustración 103).

Análisis Energía 5.2: Energía nivel 5. Feedforward. 20 Neuronas

Entrenamiento




Ilustración 104: Resultados del entrenamiento del Análisis Energía 5.2

Tras 300 iteraciones conseguimos alcanzar un error de 0.01431 el cual puede ser consistente a la hora de clasificar (ilustración 104). Aumentando el número de iteraciones podríamos reducir el error a costa de aumentar el tiempo de procesado, por lo que en caso de ser válido el resultado se podrá considerar aceptable.




Ilustración 105: Matriz de confusión del entrenamiento del Análisis Energía 5.2

En este caso el resultado de la simulación de las señales entrenadas es ligeramente inferior al obtenido en la red de base radial, siendo un 99,6 % de acierto un magnífico resultado aparente (ilustración 105).

Simulación




Ilustración 106: Matrices de confusión de la simulación del Análisis Energía 5.2

También obtenemos unos buenos resultados en la clasificación ya que el porcentaje de acierto es de 95% para sanos, 95% para pista interna, 95% para pista externa y 95% en bola (ilustración 106).

Análisis Energía 5.3: Energía nivel 5. Rec. Patrones. 20 neuronas

Entrenamiento




Ilustración 107: Entrenamiento del Análisis Energía 5.3

El resultado del entrenamiento es muy bueno ya que con solo 300 iteraciones se consigue un error de 7×10^{-4} , muy inferior que en el caso anterior y con un análisis de similar duración (ilustración 107).




Ilustración 108: Matriz de confusión del entrenamiento del Análisis Energía 5.3

La clasificación del entrenamiento (ilustración 108) nos confirma el buen resultado del entrenamiento. Si sumamos el resultado del error cometido en el entrenamiento, su validación y el test, y lo añadimos a los resultados de clasificación de las señales entrenadas todo hace indicar que la red está preparada para clasificar con un gran porcentaje de acierto.

Simulación

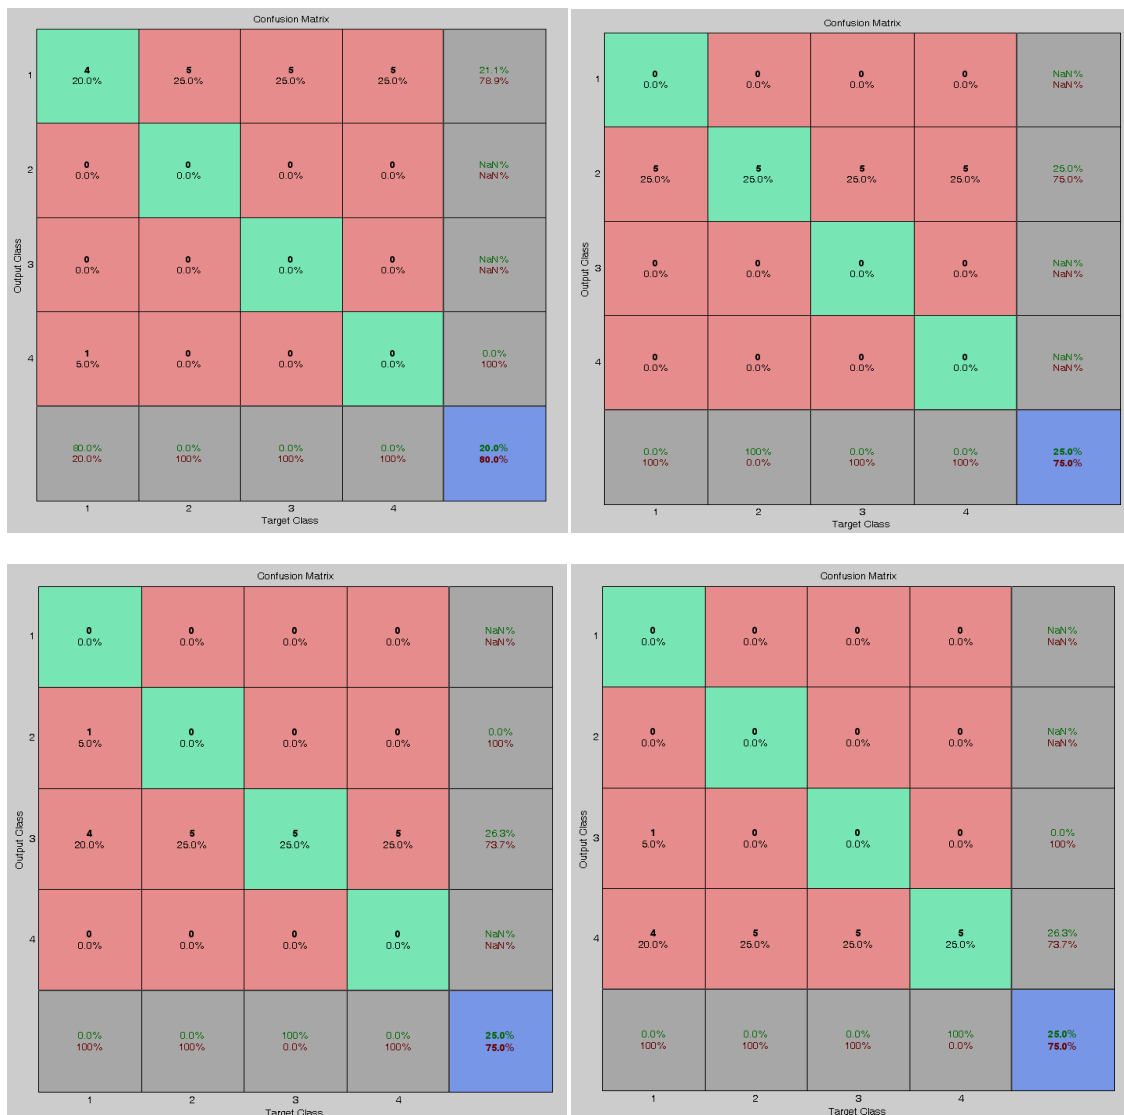


Ilustración 109: Matrices de confusión de la simulación del Análisis Energía 5.3

Los resultados obtenidos en el entrenamiento, mostrados en la ilustración 109, se corresponden con los del test, ya que este nos da unos porcentajes de acierto de 95% para rodamiento sano, 100% para rodamiento con defecto en pista interna, 95% para rodamiento con defecto en pista interna y 95 % para rodamiento con defecto en bola.

Análisis 5.4. Energía nivel 5: SOM. 10x10 neuronas.

Entrenamiento

Como vemos en la ilustración 110, las señales se dispersan por la malla en general, lo cual indica que la red es capaz de diferenciar y agrupar los distintos tipos de señales que hay. Para saber cómo o si tiene algún sentido realizamos las cuatro simulaciones, una por cada tipo de señal, ya que en este caso procede en mayor medida que en el análisis de coeficientes.




Ilustración 110: Resultados del entrenamiento del Análisis 5.4

Simulación




Ilustración 111: Resultados de la simulación del Análisis 5.4

Se aprecia una gran diferencia respecto a los análisis anteriores de redes SOM clasificando coeficientes wavelets (ilustración 111). En este caso las señales no solo se diferencian en gran medida entre sí, sino que comienzan a establecerse en zonas concretas, cada cual supuestamente correspondientes a cada tipo de señal. Esto es una simple hipótesis ya que el patrón no nos permite obtener un resultado mejor para este tipo de red.

NIVEL 8

Para el análisis del nivel ocho de descomposición wavelet emplearemos el siguiente patrón de energía:

PATRÓN DE ENERGÍA	Nº paquete
Mejor paquete	145
2º mejor paquete	183
3º mejor paquete	181
4º mejor paquete	175
5º mejor paquete	147

Tabla 13: Patrón de energía. Nivel 8




Ilustración 112: Gráfica de energías centrada en el rango de valores empleados

Como se aprecia los cinco niveles elegidos se pueden diferenciar entre sí salvo excepción del nivel 175. Sin embargo la energía de cada señal es menor que en el caso de nivel cinco y las señales son algo más difusas.

Análisis Energía 8.1: Energía nivel 8. RBF

Entrenamiento

Como vemos en el gráfico del entrenamiento (ilustración 113) la convergencia es más lenta que en el caso de nivel cinco. En este caso alcanzamos el error objetivo de 10^{-5} con 220 neuronas.

Como es habitual en las redes en base radial la clasificación de los inputs de entrenamiento es perfecta.




Ilustración 113: Resultado del entrenamiento del Análisis Energía 8.1




Ilustración 114: Matriz de confusión del entrenamiento del Análisis Energía 8.1

Simulación

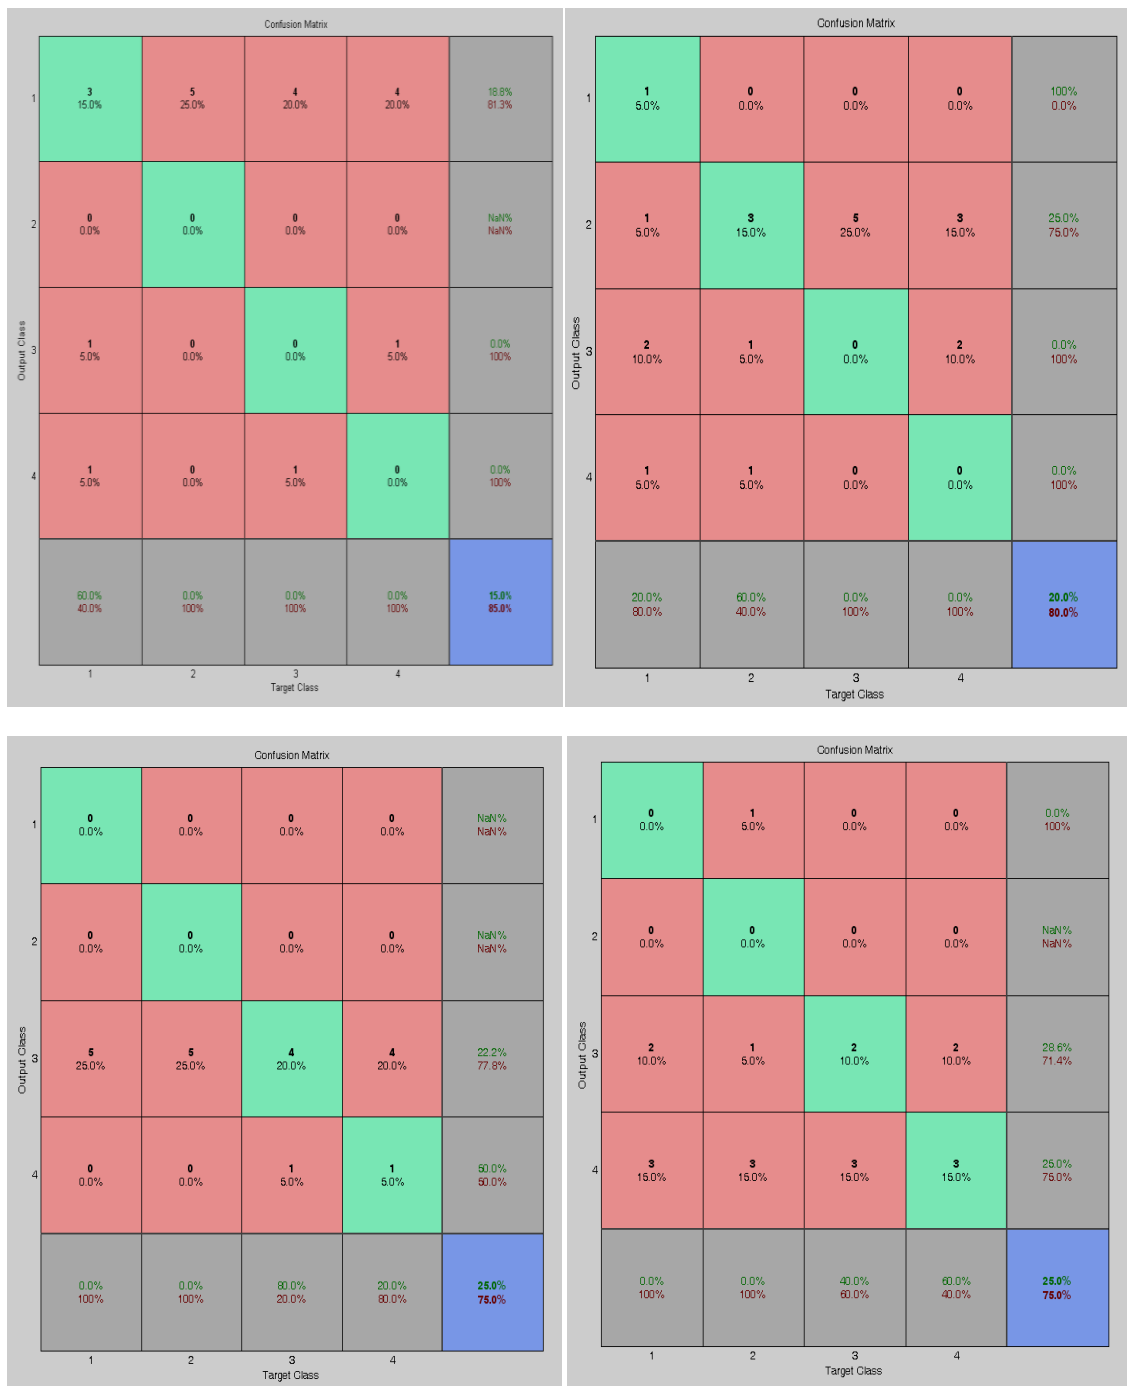


Ilustración 115: Matrices de confusión de la simulación del Análisis Energía 8.1

Como el entrenamiento ha requerido un número mayor de neuronas los resultados de la simulación han decaído, acertando en rodamiento sano el 80%, en pista interna el 60%, en pista externa el 90% y en bola el 60% (ilustración 115).

En este primer análisis se comienza a constatar que el nivel de descomposición ocho dará peores resultados que el de nivel de descomposición cinco.

Análisis Energía 8.2: Energía nivel 8. Feedforward. 20 Neuronas

Entrenamiento

El entrenamiento es muy estable pero solo se alcanzan las 82 iteraciones (ilustración 116), lo que genera un error que se aprecia en la matriz de confusión del entrenamiento. Observamos, en la ilustración 117, un 73,3% de acierto en rodamientos de bola, confundiendo varias de ellas con defecto en pista externa.




Ilustración 116: Resultado del entrenamiento del Análisis Energía 8.2




Ilustración 117: Matriz de confusión del entrenamiento del Análisis Energía 8.2

Simulación



Ilustración 118: Matrices de confusión de la simulación del Análisis Energía 8.2

Alcanzamos un 100% de acierto en rodamiento sano, pista interna y pista externa, pero en bola un 70% existiendo un 20% de posibilidades de confusión con defecto en pista externa (ilustración 118). Esto ha ocurrido como consecuencia del error en el entrenamiento que implica que ciertas señales de rodamientos con defecto en bola se confundan con señales de rodamiento con defecto en pista externa. Si volvemos a la Ilustración 109 comprobamos en el gráfico de energías como la señal amarilla correspondiente a defectos en bola es más difusa que las demás y coincide en varias ocasiones con la señal azul correspondiente a señales de defecto en pista interna.

Análisis Energía 8.3: Energía nivel 8. Rec. Patrones. 20 Neuronas

Entrenamiento

El entrenamiento de esta red es de bastante menor calidad que su versión de nivel cinco debido a que alcanzamos un error mayor realizando tres veces más iteraciones. Aún así sus resultados convergen y se clasifican de manera eficaz, como muestran las ilustraciones 119 y 120.




Ilustración 119: Resultados del entrenamiento del Análisis Energía 8.3




Ilustración 120: Matriz de confusión del entrenamiento del Análisis Energía 8.3

Simulación

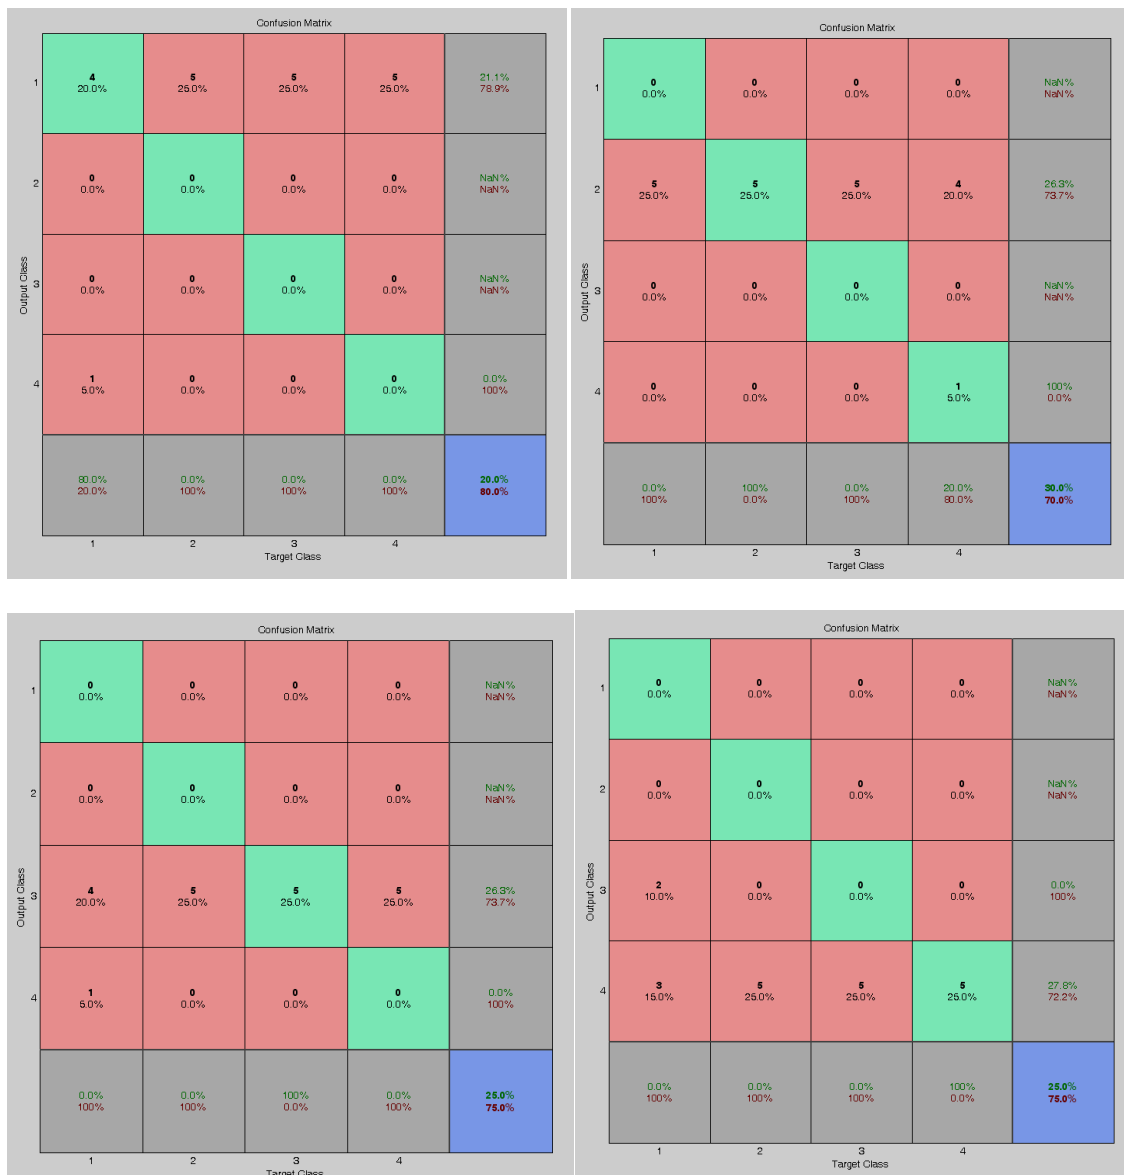


Ilustración 121: Matrices de confusión de la simulación del Análisis Energía 8.3

Los resultados de acierto en la simulación son de 95% en rodamiento sano, en pista interna y en pista externa, y de 90 % en bola (ilustración 121).

Comparando este tipo variante de red perceptrón multicapa con la otra variante empleada, la feedforward, ésta se muestra más precisa en casos más complicados como el caso de nivel de descomposición ocho que estamos tratando. Sin embargo es más inestable, pudiendo dar también como resultado unos índices muy bajos.

Análisis Energía 8.4: Energía nivel 8. SOM. 10x10 neuronas.

Entrenamiento

Aparentemente el entrenamiento de esta red (ilustración 122) agrupa entradas en zonas de manera más cuantitativa que en el caso de nivel cinco (ilustración 110), pero como vemos a continuación los resultados de la simulación son algo más confusos que en el caso anterior.




Ilustración 122: Resultados del entrenamiento del Análisis Energía 8.4

Simulación




Ilustración 123: Resultados de la simulación del Análisis Energía 8.4

Los resultados obtenidos son peores que para el caso de nivel de descomposición cinco (ilustración 111), ya que en este caso, la simulación muestra resultados demasiado dispersos (ilustración 123).

CONCLUSIÓN

Con este último método, generando un patrón para cada señal a partir de la energía contenida en una serie de paquetes wavelet en los niveles de descomposición cinco y ocho obtenemos clasificaciones con un alto porcentaje de acierto para redes en base radial y redes perceptrón multicapa de dos tipos. Además para redes SOM obtenemos unos resultados prometedores para futuros desarrollos.

En el siguiente apartado analizaremos únicamente los resultados para diferentes variables.

5.5 Resumen

A continuación mostraremos una tabla que resume todos los análisis realizados de CFS y Energía wavelet así como los resultados obtenidos. Para cada análisis se ha actuado sobre la topología de red, el nivel de descomposición, el número de neuronas y el error objetivo.

Análisis	Red	Nivel. Descom.	Nº Neur.	Resultado Entrenamiento			Resultado Simulación (%)			
				Error	Iter	[%]	Sano	Inner	Outer	Ball
Energía	RBF	5	171	10^{-5}	-	100	95	80	100	100
Energía	RBF	5	136	10^{-4}	-	100	95	95	100	100
Energía	RBF	5	83	10^{-3}	-	100	95	90	95	100
Energía	RBF	5	30	10^{-2}	-	100	95	95	90	100
Energía	RBF	5	4	10^{-1}	-	75,4	75	100	60	60
Energía	FF	5	5	$2,27 \cdot 10^{-2}$	300	97,3	95	100	75	85
Energía	FF	5	10	$9,54 \cdot 10^{-3}$	300	99,6	95	95	100	95
Energía	FF	5	20	$8,52 \cdot 10^{-3}$	300	99,6	95	95	100	95
Energía	FF	5	40	$7,36 \cdot 10^{-3}$	300	99,2	95	95	95	95
Energía	FF	5	80	$5,08 \cdot 10^{-3}$	286	99,2	95	95	95	95
Energía	FF	5	200	$3,75 \cdot 10^{-3}$	300	100	95	100	95	95
Energía	PR	5	5	$1,07 \cdot 10^{-3}$	300	98,8	95	100	95	95
Energía	PR	5	10	$1,99 \cdot 10^{-3}$	300	98,8	95	95	95	95
Energía	PR	5	20	$1,27 \cdot 10^{-3}$	300	98,8	95	100	95	95
Energía	PR	5	40	$6,28 \cdot 10^{-4}$	78	99,6	95	95	90	95
Energía	PR	5	80	$9,04 \cdot 10^{-4}$	115	98,3	95	95	80	90
Energía	PR	5	200	0,928	78	25,4	30	15	10	10
Energía	RBF	8	220	10^{-5}	-	100	80	60	90	60
Energía	RBF	8	230	10^{-4}	-	100	50	10	60	65
Energía	RBF	8	220	10^{-3}	-	100	80	60	90	60
Energía	RBF	8	92	10^{-2}	-	98,8	95	90	95	80
Energía	RBF	8	4	10^{-1}	-	83,3	95	75	100	70
Energía	FF	8	5	$7,68 \cdot 10^{-2}$	200	83,8	95	85	80	60
Energía	FF	8	10	$5,26 \cdot 10^{-2}$	300	89,6	100	100	100	65
Energía	FF	8	20	$5,65 \cdot 10^{-2}$	82	90,8	100	100	100	70
Energía	FF	8	40	$3,79 \cdot 10^{-2}$	270	90,8	95	95	85	75
Energía	FF	8	80	$5,29 \cdot 10^{-2}$	60	91,7	100	100	95	65
Energía	FF	8	200	$2,04 \cdot 10^{-2}$	224	94,6	95	80	95	90

Análisis	Red	Nivel. Descom.	Nº Neur.	Resultado Entrenamiento			Resultado Simulación (%)			
				Error	Iter	[%]	Sano	Inner	Outer	Ball
Energía	PR	8	5	$5,57 \cdot 10^{-2}$	131	85,8	95	75	100	75
Energía	PR	8	10	$3,30 \cdot 10^{-2}$	85	90,4	95	100	100	65
Energía	PR	8	20	$3,34 \cdot 10^{-3}$	171	96,7	95	95	95	90
Energía	PR	8	40	$1,19 \cdot 10^{-2}$	174	95,8	95	95	100	85
Energía	PR	8	80	$1,20 \cdot 10^{-1}$	58	50	0	85	80	0
Energía	PR	8	200	$4,58 \cdot 10^{-2}$	156	90	95	90	85	60
CFS	RBF	5.18	239	10^{-5}	-	100	0	0	100	0
CFS	RBF	5.18	239	10^{-4}	-	100	0	0	100	0
CFS	RBF	5.18	239	10^{-3}	-	100	0	0	100	0
CFS	RBF	5.18	175	10^{-2}	-	97,9	0	0	0	100
CFS	RBF	5.18	91	10^{-1}	-	62,9	0	0	100	0
CFS	RBF	5.29	239	10^{-5}	-	100	0	0	100	0
CFS	RBF	5.29	239	10^{-4}	-	100	0	0	100	0
CFS	RBF	5.29	239	10^{-3}	-	100	0	0	100	0
CFS	RBF	5.29	210	10^{-2}	-	97,5	0	0	0	100
CFS	RBF	5.29	92	10^{-1}	-	63,3	0	0	100	0
CFS	FF	5.18	20	$1,75 \cdot 10^{-1}$	28	38,7	0	0	100	0
CFS	FF	5.18	50	$2,20 \cdot 10^{-1}$	32	55,5	0	0	100	0
CFS	FF	5.18	100	$4,22 \cdot 10^{-1}$	32	41,9	0	0	0	100
CFS	FF	5.18	200	$5,84 \cdot 10^{-1}$	34	58,1	0	0	100	0
CFS	FF	5.18	400	$9,41 \cdot 10^{-1}$	36	58,2	0	0	100	0
CFS	FF	5.29	20	$1,98 \cdot 10^{-1}$	30	40,8	15	0	100	10
CFS	FF	5.29	50	$2,70 \cdot 10^{-1}$	32	57,5	25	25	15	10
CFS	FF	5.29	100	$5,54 \cdot 10^{-1}$	33	43,3	25	45	25	5
CFS	FF	5.29	200	$5,03 \cdot 10^{-1}$	34	50,8	10	10	70	0
CFS	FF	5.29	400	3,20	33	58,8	30	30	30	35
CFS	PR	5.18	20	$7,40 \cdot 10^{-2}$	43	52,9	100	40	0	30
CFS	PR	5.18	50	$9,52 \cdot 10^{-2}$	26	37,2	90	15	0	15
CFS	PR	5.18	100	$2,23 \cdot 10^{-1}$	24	31,2	40	15	0	10
CFS	PR	5.18	200	$3,40 \cdot 10^{-1}$	20	30,1	45	10	0	10
CFS	PR	5.18	400	$5,14 \cdot 10^{-1}$	21	30,2	30	15	5	15
CFS	PR	5.29	20	$6,21 \cdot 10^{-2}$	51	61,2	90	40	15	15
CFS	PR	5.29	50	$9,31 \cdot 10^{-2}$	29	41,1	95	20	5	20
CFS	PR	5.29	100	$3,94 \cdot 10^{-1}$	19	29,9	45	0	0	20
CFS	PR	5.29	200	$3,88 \cdot 10^{-1}$	26	32,2	40	15	0	30
CFS	PR	5.29	400	$6,09 \cdot 10^{-1}$	20	29,6	20	20	0	15
CFS	RBF	8.174	238	10^{-5}	-	100	0	0	100	0
CFS	RBF	8.174	239	10^{-4}	-	100	0	0	100	0
CFS	RBF	8.174	239	10^{-3}	-	100	0	0	100	0
CFS	RBF	8.174	145	10^{-2}	-	99,6	0	0	100	0
CFS	RBF	8.174	83	10^{-1}	-	75,4	0	0	100	0
CFS	RBF	8.145	238	10^{-5}	-	100	0	0	100	0
CFS	RBF	8.145	239	10^{-4}	-	100	0	0	100	0
CFS	RBF	8.145	239	10^{-3}	-	100	0	0	100	0
CFS	RBF	8.145	204	10^{-2}	-	99,6	0	0	100	0
CFS	RBF	8.145	84	10^{-1}	-	72,2	0	0	100	0
CFS	FF	8.174	20	$3,34 \cdot 10^{-2}$	26	45	55	5	15	30
CFS	FF	8.174	50	$1,71 \cdot 10^{-2}$	36	64,2	25	25	40	20

Análisis	Red	Nivel. Descom.	Nº Neur.	Resultado Entrenamiento			Resultado Simulación (%)			
				Error	Iter	[%]	Sano	Inner	Outer	Ball
CFS	FF	8.174	100	$1,59 \cdot 10^{-2}$	33	57,1	45	10	45	50
CFS	FF	8.174	200	$2,16 \cdot 10^{-2}$	35	59,2	40	5	25	15
CFS	FF	8.174	400	$3,05 \cdot 10^{-3}$	73	72,9	45	35	20	0
CFS	FF	8.145	20	$2,47 \cdot 10^{-2}$	33	60,8	65	30	40	0
CFS	FF	8.145	50	$2,96 \cdot 10^{-2}$	33	59,8	90	25	30	10
CFS	FF	8.145	100	$3,01 \cdot 10^{-2}$	31	53,8	45	20	20	25
CFS	FF	8.145	200	$2,05 \cdot 10^{-2}$	45	65,8	65	10	25	25
CFS	FF	8.145	400	$2,60 \cdot 10^{-3}$	87	73,8	80	30	10	10
CFS	PR	8.174	20	$2,71 \cdot 10^{-2}$	26	44,6	35	30	25	45
CFS	PR	8.174	50	$7,27 \cdot 10^{-2}$	41	53,3	0	45	50	25
CFS	PR	8.174	100	$8,91 \cdot 10^{-2}$	30	34,2	55	5	30	5
CFS	PR	8.174	200	$2,14 \cdot 10^{-1}$	26	35,2	25	25	0	55
CFS	PR	8.174	400	$4,29 \cdot 10^{-2}$	71	69,8	45	45	15	55
CFS	PR	8.145	20	$7,53 \cdot 10^{-2}$	24	29,2	0	10	55	30
CFS	PR	8.145	50	$7,82 \cdot 10^{-2}$	30	38,3	65	45	0	65
CFS	PR	8.145	100	$1,76 \cdot 10^{-1}$	23	23,5	60	45	0	0
CFS	PR	8.145	200	$1,53 \cdot 10^{-1}$	21	32,5	100	15	0	0
CFS	PR	8.145	400	$4,55 \cdot 10^{-1}$	49	25,8	0	0	0	100
CFS	RBF	10.18	239	10^{-5}	-	100	0	100	0	0
CFS	RBF	10.18	239	10^{-4}	-	100	0	100	0	0
CFS	RBF	10.18	189	10^{-3}	-	99,6	0	100	0	0
CFS	RBF	10.18	81	10^{-2}	-	74,6	0	100	0	0
CFS	RBF	10.18	42	10^{-1}	-	45,4	0	100	0	0
CFS	RBF	10.29	239	10^{-5}	-	100	0	100	0	0
CFS	RBF	10.29	239	10^{-4}	-	100	0	100	0	0
CFS	RBF	10.29	192	10^{-3}	-	99,6	0	100	0	0
CFS	RBF	10.29	86	10^{-2}	-	76,2	0	100	0	0
CFS	RBF	10.29	40	10^{-1}	-	44,2	0	100	0	0
CFS	FF	10.698	20	$7,48 \cdot 10^{-2}$	28	49,6	50	20	35	15
CFS	FF	10.698	50	$4,93 \cdot 10^{-2}$	28	49,2	55	20	15	40
CFS	FF	10.698	100	$4,83 \cdot 10^{-2}$	32	50	5	20	15	45
CFS	FF	10.698	200	$2,61 \cdot 10^{-2}$	56	67,9	25	20	60	20
CFS	FF	10.698	400	$3,81 \cdot 10^{-2}$	47	62,5	35	10	45	15
CFS	PR	10.698	20	$5,39 \cdot 10^{-2}$	44	58,3	50	5	30	15
CFS	PR	10.698	50	$8,39 \cdot 10^{-2}$	43	44,2	10	20	30	30
CFS	PR	10.698	100	$1,38 \cdot 10^{-1}$	28	40,4	0	15	70	30
CFS	PR	10.698	200	$2,26 \cdot 10^{-1}$	21	24,6	5	0	100	0
CFS	PR	10.698	400	$2,29 \cdot 10^{-1}$	57	22,5	0	0	100	0

Tabla 14: Resumen de todos los análisis realizados

Con todos estos análisis hemos querido buscar los límites tanto en precisión del error como en número de neuronas de las redes para analizar el distinto comportamiento de las redes. Los mejores resultados de cada análisis se muestran en gris siempre y cuando éstos sean válidos.

Las conclusiones se detallan en el Capítulo 6.

CAPÍTULO 6: Conclusiones

6.1 Conclusiones sobre los resultados obtenidos

En el apartado 5.5 se pueden ver los resultados de todos los análisis realizados así como en el resto del Capítulo 5. De ellos se extraen las siguientes conclusiones:

- Los análisis de señal íntegra y RCFS no ofrece resultados que posibiliten su clasificación por dos razones:
 - Requiere un elevado coste computacional.
 - La red neuronal tiene problemas de entrenamiento cuando el número de neuronas es tan elevado.
- El análisis de coeficientes Wavelet (CFS) no arroja buenos resultados como en el caso de señales con excitación estacionarias. Esto se debe básicamente a la gran diferencia que existe entre los coeficientes de cada señal. Centrándonos en este tipo de análisis:
 - La red de base radial no ofrece resultados válidos en este caso, ya que el entrenamiento no es capaz de obtener patrones.
 - Las redes perceptrón multicapa mejoran notablemente en el entrenamiento cuando se emplea nivel ocho de descomposición en comparación con el nivel cinco de descomposición, para casos de un gran número de neuronas (400), Sin embargo fallan en la clasificación.
 - En este caso las redes perceptrón multicapa, especialmente la de reconocimiento de patrones se muestran poco estables, pudiendo obtener tanto mejores como peores resultados de entrenamiento y simulación.
 - Como regla general, las redes MLP mejoran a medida que aumentamos el número de neuronas, siempre hasta cierto nivel en el que la red queda sobreentrenada.
- El análisis de energía Wavelet es el que mejores resultados proporciona para los tres tipos de redes. Es mejor en nivel de descomposición cinco que en nivel ocho y ofrece muy buenos resultados con muy pocas neuronas, ya que el número de entradas es ahora mucho menor. Además los tiempos de entrenamiento y clasificación son muy bajos.

6.2 Comparación con otros trabajos

En este campo existen numerosos estudios, que en su gran mayoría se desarrollan para señales con excitación estacionaria y con diferentes métodos de clasificación.

Como ejemplo cabe destacar el PFC de Omar Lara Castro [7]. Este Proyecto analiza de forma muy similar señales estacionarias para redes perceptrón multicapa en diferentes niveles de descomposición y velocidades angulares.

Estos son algunos de los mejores porcentajes de clasificación obtenidos:

600 RPM				1200 RPM				1800 RPM			
n	10	20	30	n	10	20	30	n	10	20	30
N	100.00	100.00	100.00	N	100.00	100.00	100.00	N	100	100.00	100.00
I	100.00	100.00	100.00	I	100.00	98.67	98.67	I	96.00	100.00	100.00
B	97.33	97.33	100.00	B	100.00	100.00	100.00	B	100.00	100.00	100.00
O	100.00	100.00	100.00	O	100.00	100.00	100.00	O	100.00	100.00	100.00
ST	99.33	99.33	100.00	ST	100.00	99.67	99.67	ST	99.00	100.00	100.00
T	99.55			T	99.78			T	99.67		

Tabla 15: Resultados de Clasificación para un nivel de descomposición 5 [7]

Donde:

n: Neuronas en la capa oculta de la red neuronal

N: Tasa de éxito para la clasificación de Rodamientos sin defecto

I: Tasa de éxito para la clasificación de Rodamientos con defecto en pista interna

B: Tasa de éxito para la clasificación de Rodamientos con defeco en Bola

O: Tasa de éxito para la clasificación de Rodamientos con defeco en pista externa

ST: Tasa de éxito general por cantidad de neuronas en capa oculta

T: Tasa de éxito total por velocidad de rotación

600 RPM				1200 RPM				1800 RPM			
n	10	20	30	n	10	20	30	n	10	20	30
N	100.00	100.00	100.00	N	100.00	100.00	100.00	N	100.00	100.00	100.00
I	94.67	93.33	90.67	I	96.00	94.67	97.33	I	100.00	100.00	100.00
B	97.33	96.00	97.33	B	100.00	96.00	94.67	B	100.00	100.00	100.00
O	100.00	96.00	98.67	O	98.67	100.00	100.00	O	100.00	100.00	100.00
ST	98.00	96.33	96.67	ST	98.67	97.67	98.00	ST	100.00	100.00	100.00
T	97.00			T	98.11			T	100.00		

Tabla 16: Resultados de Clasificación para un nivel de descomposición 8 [7]

Como se aprecia los resultados son ligeramente superiores a los obtenidos en el presente Proyecto. Esto se debe principalmente al carácter estacionario de la señal, lo que denota que el resultado obtenido en la clasificación de señales transitorias es muy satisfactorio.

6.3 Puntos de mejora

Durante la realización del PFC surgió un contratiempo en la fase de adquisición de datos que han podido afectar de algún modo a los resultados. Este fue la falta del elemento roscado magnético que permitía la unión fija del acelerómetro al soporte del rodamiento. Para solventarlo se unieron ambas piezas con pegamento de contacto. Para futuros desarrollos se deberá mejorar la unión entre el acelerómetro y el soporte del rodamiento, que en este caso se realizó con adhesivo de contacto, por un elemento magnético o roscado.

Por último destacar una mejora que se realizó en la fase final de redacción del Proyecto, y esta fue la modificación del programa de preprocesamiento wavelet en su fase de obtención de las diferencias energéticas. Inicialmente el programa calculaba la diferencia de cada señal de rodamiento sano con cada señal con defecto. Esto suponía largos tiempos de ejecución. Esto se sustituyó por un cálculo de la diferencia energética entre las señales de rodamiento con defecto y un promedio de las señales de rodamiento sano.

6.4 Futuros desarrollos

En el desarrollo del PFC han quedado abiertas nuevas vías de investigación. Estos métodos tienen una clara aplicación práctica y sería muy interesante aplicarlos en casos reales. Por ejemplo colaborando con el departamento de mantenimiento de alguna empresa que de acceso a equipos de la Universidad a tomar datos periódicos de sus equipos con el fin de implementar un nuevo sistema de mantenimiento preventivo con este método.

Otra vía se abre con las redes neuronales de aprendizaje no supervisado como la SOM, que han demostrado en casos concretos que con un mejor ajuste pueden llegar a funcionar. Esto mejoraría el método ya que ya no tendríamos que indicarle a la red en el entrenamiento el tipo de objetivo que estamos introduciendo, y esta sería capaz de diferenciar por sí misma.

6.5 Conocimientos empleados y adquiridos

Cuando se empieza en un PFC como este hay gran cantidad de nuevos conceptos, pero muchos conocimientos ya se poseen.

Resultaron muy útiles las habilidades con Matlab adquiridas en la asignatura “Métodos Numéricos”, los conocimientos de señales vibratorias y transformadas de Fourier de “Vibraciones Mecánicas”, “Mecánica Industrial” o “Acústica Industrial” así como las habilidades para adquirir y procesar señales aprendidas con el profesor Higinio Rubio Alonso en Trabajos Dirigidos.

En cuanto a los conocimientos adquiridos resultaron imprescindibles los estudios de las transformadas wavelet y las redes neuronales así como la inestimable ayuda de la Dra. Cristina Castejón Sisamón así como la de Alberto Ordoñez Rangel.

Presupuesto

A continuación se detallará lo que costaría realizar este Proyecto Fin de Carrera como un Proyecto de I+D de una empresa interesada en mejorar los métodos de detección de fallos en sus equipos. Dividiremos los costes en tres apartados: Banco de ensayos, Procesamiento y clasificación, y Elaboración de informe. Contabilizaremos el coste de equipos por día utilizado como su coste total amortizado en un año por día utilizado.

Adjuntaremos un diagrama de Gantt del reparto de tiempos y tareas a lo largo de la realización del PFC, excluyendo los meses de Julio y Agosto en los que no trabajé en el Proyecto.

Unidad.	Resumen	Cantidad	PVP/día	Total
Banco de ensayos (Coste/amortización de equipos de 1 año)				
días	MFS-LITE	6,00	11,30 €	67,81 €
	Machine Fault Simulator Package nº2. Incluye: - Motor - Acelerómetro - Variador de frecuencia - Acoplamientos - Rodamientos defectuosos			
días	Filtro antialiasing	6,00	0,25 €	1,48 €
	Filtro antialiasing x 3 unidades			
días	Equipo informático banco de ensayos	6,00	3,42 €	20,55 €
	Ordenador portatil más software con licencia Testpoint			
días	Tarjeta adquisición de datos	6,00	0,82 €	4,93 €
	Tarjeta adquisición de datos Keithley modelo KUSB 300			
días	Mano de obra	6,00	147,95 €	887,67 €
	Ingeniero industrial a jornada completa más técnico de laboratorio de apoyo			
Procesamiento y clasificación (Coste/amortización de equipos de 1 año)				
días	Equipo informático	30,00	3,97 €	119,18 €
	Ordenador de sobremesa más software con licencia Matlab 2009r			
días	Mano de obra	30,00	87,67 €	2.630,14 €
	Ingeniero industrial a jornada completa			
Elaboración de informe (Coste/amortización de equipos de 1 año)				
días	Equipo informático	25,00	3,84 €	95,89 €
	Ordenador de sobremesa más software con licencia MS Office 2007			
días	Mano de obra	25,00	87,67 €	2.191,78 €
	Ingeniero industrial a jornada completa			
			TOTAL	6.019,42 €

El presupuesto total de este proyecto asciende a la cantidad de 6.019,42€

Leganés a 13 de marzo de 2011

El ingeniero proyectista

Fdo. Miguel Albertos Cabañas

Bibliografía

- [1] Tendencias del Mantenimiento Predictivo: Ricardo Santamaría Holek. Artículo de Tecnología Avanzada para Mantenimiento S.A. de C.V. 2008. México.
- [2] La Evolución y Perspectivas del Mantenimiento Predictivo Proactivo en la Industria: Dr Pedro Saavedra González y Cristián Molina Vicuña. VI Congreso Panamericano de Ingeniería de mantenimiento. Septiembre 2004.
- [3] Wikipedia. www.wikipedia.com
- [4] Thomson, W.T., Teoría de vibraciones: aplicaciones, Prentice – Hall Hisp. 1983
- [5] R.B. Randall, Frequency Analysis, Brüel & Kjær. 3rd edition (1987)
- [6] Penkova Vassileva, María. Análisis de señales vibratorias. Ciencia y Sociedad, Vol. XXXIII, Núm. 1, enero-marzo, 2008, pp. 29-46 Instituto Tecnológico de Santo Domingo República Dominicana
- [7] Omar José Lara Castro. Identificación de la condición de Rodamientos de Bola a través del cálculo de Energía Wavelet y Redes Neuronales Artificiales. Proyecto Fin de Carrera. Universidad Carlos III. Leganés. Julio 2010.
- [8] Lic. Juan J. Piñeiro, Ing. Andreas E. Klempnow. Análisis y diagnóstico de falla en un rodamiento que opera a bajas vueltas. IV Conferencia Panamericana de END Buenos Aires – Octubre 2007.
- [9] Estupiñan, Edgar - Saavedra, Pedro. Técnicas de diagnostico para el análisis de vibraciones de rodamientos. Universidad de Concepción. 2003. <http://www.mt-online.com/>
- [10] Murray Spiegel. “Teoría y Problemas de Análisis de Fourier”. McGraw-Hill serie de compendios Schaum, 1981.
- [11] Ruel Churchill. “Series de Fourier y Problemas de Contorno”. McGraw-Hill, 1978.
- [12] Daubechies, “Ten Lectures on Wavelets”, Society for Industrial and Applied Mathematics, Philadelphia, 1992.
- [13] Apuntes de Teoría de Señales. Introducción a la Transformada Wavelet. Departamento de Señales y sistemas. Universidad de Navarra. 2006
- [14] S.G. Mallat, “A Wavelet Tour of Signal Processing”, Academic Press, London, 1998.
- [15] S.G. Mallat, “A Theory for Multiresolution Signal Decomposition: the Wavelet Representation”, IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol. 2, No. 7, July 1989, pp.
- [16] Informática Aplicada a la Ingeniería de Procesos – Orientación I. Redes Neuronales: Conceptos Básicos y Aplicaciones. Profesores: Carlos Alberto Ruiz, Marta Susana Basualdo. Autor: Damián Jorge Matich. Rosario. Marzo 2001.
- [17] Neuronal Networks: Basics and Applications, by R. Lackes and D. Mack, in collaboration with J. Ziola and K. Ahern. CBT (Computer Based Training) Springer, Verlag Berlin Heidelberg 1998.
- [18] Tutorial de Redes Neuronales. Universidad Politécnica de Madrid, España (www.gc.ssr.upm.es/inves/neuronal/ann2/anntuto.htm). Noviembre 2010.

- [19] Tutorial de Matlab R2008a. Wavemenu y Redes Neuronales. Mathworks. Copyright 1984 – 2009.
- [20] Redes neuronales artificiales y mapas autoorganizados. David Martínez González. Sistemas Expertos e Inteligencia Artificial. 3º I.T.I.G. Curso 2004-05. Universidad de Burgos.
- [21] Redes Neuronales y Sistemas Borrosos. Bonifacio Martín del Río, Alfredo Sanz Molina. Ra-Ma 2001
- [22] Apuntes de rodamientos. Fundación Universidad de Atacama Escuela Técnico Profesional. Septiembre 2008.
- [23] Apuntes de rodamientos. V.Badiola. Dpto. ingeniería mecánica, energética y de materiales. Universidad de Navarra. Curso 2003-2004
- [24] Bearing failures and their causes. SKF. Publication PI 401 E. 1994
- [25] Rolling Bearing Damage. Recognition of damage and bearing inspection. FAG Bearing Corporation. Publ. No. WL 82 102/2 ED. 2006
- [26] TestPointTM. “Techniques and reference”, Fourth Edition. Capital Equipment Corporation, 2002.
- [27] El País.com. www.elpais.com. Noviembre de 2010.